

Интернет-журнал «Наукоедение» ISSN 2223-5167 <http://naukovedenie.ru/>

Том 9, №2 (2017) <http://naukovedenie.ru/vol9-2.php>

URL статьи: <http://naukovedenie.ru/PDF/54TVN217.pdf>

Статья опубликована 19.04.2017

Ссылка для цитирования этой статьи:

Пятакович В.А., Василенко А.М., Мироненко М.В. Нейросетевые архитектуры для решения задач классификации информационных полей морских объектов, методика их обучения // Интернет-журнал «НАУКОВЕДЕНИЕ» Том 9, №2 (2017) <http://naukovedenie.ru/PDF/54TVN217.pdf> (доступ свободный). Загл. с экрана. Яз. рус., англ.

УДК 534.222:623.98

Пятакович Валерий Александрович

ФГКВОУ ВО «Тихоокеанское высшее военно-морское училище имени С.О. Макарова», Россия, Владивосток¹
Начальник научно-исследовательской лаборатории
Кандидат технических наук, доцент
E-mail: pva.877com@mail.ru

Василенко Анна Михайловна

ФГКВОУ ВО «Тихоокеанское высшее военно-морское училище имени С.О. Макарова», Россия, Владивосток
Научный сотрудник научно-исследовательской лаборатории
Кандидат технических наук
E-mail: kahunya@gmail.com

Мироненко Михаил Владимирович

Специальное конструкторское бюро средств автоматизации морских исследований ДВО РАН, Россия, Южно-Сахалинск
Главный научный сотрудник лаборатории гидрофизики
Доктор технических наук, профессор
E-mail: professor@mail.primorye.ru

**Нейросетевые архитектуры для решения задач
классификации информационных полей морских
объектов, методика их обучения**

Аннотация. К настоящему времени разработано большое количество различных типов нейросетей, имеющих свои отличительные особенности. Наиболее широкое распространение получили многослойные нейросети прямого распространения, или многослойные перцептроны, сокращенно - MLP (от англ. Multi Layer Perceptron). По оценкам экспертов, «когнитивные» науки (нейронауки) и «умные» системы (нейросетевые классификаторы, нейросетевые экспертные системы) являются перспективным направлением исследований в решении задач распознавания и классификации морских объектов. Нечеткие рассуждения в решении этих задач оказываются особенно полезными, когда в рассуждении присутствует неопределенность, которая затрудняет или даже исключает применение точных количественных методов и подходов. С помощью методов теории нечетких множеств можно получать аналитические выражения для количественных оценок нечетких условий принадлежности признаков к тому или иному множеству (группе классификационных признаков объекта распознавания). Они позволяют эффективно решать сложные задачи обработки информации, когда классы, подлежащие разделению, имеют произвольную форму и

¹ 690062, Россия, г. Владивосток, пер. Камский 6

пересекаются между собой, отличаются высокой точностью и эффективностью в условиях неопределенности, низким временем обучения, надежностью против помех.

В работе, по результатам своего исследования, авторы приводят анализ методов нейросетевой классификации образов, описывают наиболее подходящие архитектуры нейросетей для решения задачи распознавания информационных полей морских объектов, рассматривают процедуру их обучения.

Результаты научных разработок авторов по данной тематике защищены патентами, изданы в виде монографий и отражены в научных статьях.

Реализация разрабатываемого комплекса вычислительных операций нейронных сетей на многопроцессорных нейроподобных сверхбольших интегральных схемах в виде нейросетевой экспертной системы для распознавания и классификации измеряемых информационных полей морских объектов системой мониторинга морских акваторий, обеспечит возможность решения многофункциональных задач морской науки и оборонного комплекса Государства.

Ключевые слова: классификация морских объектов; нейросетевые архитектуры; нечёткая логика; функции принадлежности; правила вывода; нейронные сети; нейро-нечёткие модели; алгоритм обучения; системы автоматического управления

Цель и задачи. Разработка архитектуры искусственных нейронных сетей и методики их обучения для решения задач распознавания (классификации) технических источников информационных полей в морской среде.

К настоящему времени разработано большое количество различных типов нейросетей, имеющих свои отличительные особенности. Наиболее широкое распространение получили многослойные нейросети прямого распространения, или многослойные перцептроны, сокращенно - MLP (от англ. Multi Layer Perceptron). По оценкам экспертов, «когнитивные» науки (нейронауки) и «умные» системы (нейросетевые классификаторы, нейросетевые экспертные системы) являются перспективным направлением исследований в решении задач распознавания и классификации морских объектов (технических источников информационных полей в морской среде).

Сейчас искусственные нейронные сети (ИНС) особенно широко используются как средство интеллектуального анализа данных. Учитывая высокие темпы роста объемов накопленной в современных базах данных информации, роль такого анализа трудно переоценить. Нейросетевые технологии расширяют наши возможности при решении задач прогнозирования, обработки сигналов и распознавания образов.

По сравнению с традиционными методами математической статистики, классификации и аппроксимации, эти технологии обеспечивают достаточно высокое качество решений при меньших затратах. Поэтому задача реализации нестандартных архитектур ИНС в решении задач распознавания и классификации морских объектов несомненно является актуальной. В настоящее время реализация нейросетевых алгоритмов осуществляется программной, программно-аппаратной эмуляцией и чисто аппаратными средствами. Аппаратными средствами реализации ИНС (самый быстродействующий и дорогостоящий вариант) являются многопроцессорные нейроподобные сверхбольшие интегральные схемы (СБИС) и нейрочипы.

Анализ использования возможных методов классификации морских объектов и особенностей решаемой задачи позволил выделить два типа нейросетей, наиболее перспективных для решения поставленной задачи, многослойный перцептрон (обучается методом обратного распространения ошибки), и сеть встречного распространения ошибки.

По опыту работы с сетями можно сообщить, что сети первого типа более предпочтительны, так как имеется большой мировой опыт использования персептронов как распознающих сетей, и они обладают хорошим качеством. Недостатком является большое время обучения. Сети встречного распространения обучаются быстрее и обладают хорошими классификационными свойствами.

В работе приводится анализ методов нейросетевой классификации образов, описываются наиболее подходящие архитектуры нейросетей для решения задачи распознавания информационных полей морских объектов, рассматривается процедура их обучения. Результаты научных разработок авторов по данной тематике защищены патентами, изданы в виде монографий и отражены в научных статьях, некоторые из которых указаны в приведенном ниже списке литературы [1 - 11].

Реализация разрабатываемого авторами комплекса вычислительных операций ИНС на СБИС в виде нейросетевой экспертной системы (НЭС) для распознавания и классификации измеряемых информационных полей морских объектов системой мониторинга морских акваторий, обеспечит возможность решения многофункциональных задач морской науки и оборонного комплекса Государства.

Классификатор на базе многослойного персептрона

Архитектура сети. Известно, что распознаванию подлежит большое число объектов, то есть множества классифицируемых признаков имеют достаточно сложную форму в пространстве признаков (входы). В этом случае целесообразно использовать трехслойную (как минимум) сеть, которая обеспечивает разделение пространственных множеств произвольной формы. Общая структура сети представлена на разработанном авторами рис. 1.

Сеть способна классифицировать $2^3 = 8$ образов. Интерпретация выходного вектора у приведена в составленной авторами табл. 1.

Таблица 1

Таблица интерпретации выходного вектора (составлена авторами)

y_1	y_2	y_3	Интерпретация признака
0	0	0	Неизвестный объект
0	0	1	Объект № 1
0	1	0	Объект № 2
0	1	1	Объект № 3
1	0	0	Объект № 4
1	0	1	Объект № 5
1	1	0	Объект № 6
1	1	1	Объект № 7

Из табл. 1 видно, что трехслойный персептрон может распознать семь объектов и выделить неизвестный класс. На каждый нейрон первого слоя через синапсы с весами $\{T_{ij}^{(1)}\}$, $i = 1, 2, 3; j = 1, 2, 3$, подаются все компоненты входного вектора $\bar{X} = X(x_1, x_2, x_3)$. Число нейронов во втором (скрытом) слое определяется взаимным расположением и формой разделяемых множеств. В конкретном рассматриваемом случае во втором (скрытом) слое расположено три нейрона. На каждый нейрон второго слоя через синапсы с весами $\{T_{ij}^{(2)}\}$, $i = 1, 2, 3; j = 1, 2, 3$, подаются выходные сигналы первого слоя. Число нейронов третьего (выходного) слоя определяется числом рассматриваемых классов, подлежащих распознаванию. В рассматриваемом случае число выходных нейронов - три (см. рис. 1). На каждый нейрон третьего слоя через синапсы с весами $\{T_{ij}^{(3)}\}$, $i = 1, 2, 3; j = 1, 2, 3$, подаются выходные сигналы

второго слоя. Значения выходных сигналов третьего слоя образуют вектор $\bar{Y} = Y(y_1, y_2, y_3)$ решений распознавателя (классификатора). Следует отметить, что число нейронов первого и последнего слоя определяется контекстом решаемой задачи. Для определения числа нейронов в скрытых слоях нет общего подхода, как нет подхода к определению числа скрытых слоев. Обычно используется методика эмпирического итеративного подхода.

Совершенно очевидно, что число нейронов во входном слое может быть больше (например, в случае распознавания по частотной характеристике), число нейронов выхода так же определяется числом распознаваемых образов.

Нейроны, составляющие сеть, одинаковы и имеют функцию активации известного типа

$$y_n^{(i)} = \frac{1}{\pi} \arctg \left[\sum_{r=1}^{N_i} T_{2n}^{(i)} x_{2n}^{(i)} + I_n^{(i)} \right] + 0,5, \quad (1)$$

где: $x_{2n}^{(i)}$, $y_n^{(i)}$ и $I_n^{(i)}$ - значения г-го входного сигнала, выходного сигнала и внешнего смещения n-го нейрона i-го слоя; N_i - число нейронов в i-м слое; $i = 1, 2, 3$.




Рисунок 1. Структура трехслойного персептрона с трехмерными входным и выходным вектором (составлена авторами)

Предварительная обработка входных векторов производится нормализацией входного вектора признаков, полученного после анализа масок сетью MAXNET или после получения статистических оценок согласно выражения

$$X_i = \frac{(\bar{X}_i - \bar{X}_i^{\min})}{(\bar{X}_i^{\max} - \bar{X}_i^{\min})}. \quad (2)$$

Границы диапазона значений $(\bar{X}_i^{\max}, \bar{X}_i^{\min})$ известны и определяются моделью входного гидроакустического сигнала. Обучение классификатора производится на основе алгоритма обратного распространения ошибки, реализующего градиентный метод оптимизации

функционала вида: $F = \|Y(T, X^*) - Y^*\|^2$, где T - вектор синаптических весов сети; (X^*, Y^*) - обучающие пары; $\|\cdot\|$ - норма вектора. Процедуру обучения в рассматриваемой задаче можно представить в следующем виде. Пусть $\{X^{(S)}, Y^{(S)}\}$ - обучающая пара, $S = 1, \dots, S$ - число обучающих параметров. При этом необходимо реализовать следующую последовательность.

1. Задать начальные значения синаптических весов $T_{2n}^{\ell}(0)$, случайным образом из диапазона $[-1, 1]$ (или диапазона $[0, 1]$ - для случая вероятностных оценок).

2. Для очередного вектора $X^{(3)}$ получить на выходе распознающей сети значение $Y(t)$, $t = 1, 2, \dots$.

3. Вычислить ошибку $\Delta Y(t) = Y^{(3)} - Y(t)$, его норму $\|\Delta Y(t)\|$ и среднее значение нормы по итерационной формуле

$$M\|\Delta Y(t)\| = [M\|\Delta Y(t-1)\| + \|\Delta Y(t)\|] : t = 1, 2, \dots \quad (3)$$

4. Рассчитать новые значения синаптических связей T_{2n}^i по формулам:

$$T_{hK}^{(3)}(t) = T_{hK}^{(3)}(t-1) + \eta(t)\delta_K^{(3)}(t)y_h^{(2)}; \quad (4)$$

$$T_{jh}^{(2)}(t) = T_{jh}^{(2)}(t-1) + \eta(t)\delta_h^{(2)}(t)y_j^{(1)}; \quad (5)$$

$$T_{ij}^{(1)}(t) = T_{ij}^{(1)}(t-1) + \eta(t)\delta_i^{(1)}(t)x_i^{(3)}, \quad (6)$$

где $\eta(t)$ - величина, характеризующая скорость сходимости.

Ошибки распознавания определяются по формулам:

$$\delta_K^{(3)}(t) = 2f'(t)[y_K^{(3)}(t) - y_K^{(3)}]; \quad (7)$$

$$\delta_h^{(2)}(t) = f'(t) \sum_{K=1}^K [T_{hK}^{(3)}(t-1)\delta_K^{(3)}(t)]; \quad (8)$$

$$\delta_j^{(1)}(t) = f'(t) \sum_{h=1}^H [T_{jh}^{(2)}(t-1)\delta_h^{(2)}(t)]; \quad (9)$$

где $f'(t)$ - производная активационной функции нейрона.

5. Повторить шаги 2, 3, 4 до выполнения условия: $\|\Delta Y(t)\| \leq \varepsilon_1$ - характеристика точности обучения по одному примеру.
6. Повторить шаги 2, 3, 4, 5 для остальных примеров обучающей выборки.
7. Повторить шаги 2, 3, 4, 5, 6 для остальных примеров обучающей выборки до выполнения условия

$$\|\Delta Y(t)\| \leq \varepsilon_2, \quad (10)$$

где $\varepsilon_2 > 0$ - характеристика средней точности обучения по всей выборке.

Классификатор на базе сетей Кохонена - Гроссберга. Архитектура сети. Рассматриваемая нейросетевая парадигма объединяет самоорганизующиеся карты Кохонена и “звезды” Гроссберга. Общая структура сети представлена на разработанном авторами рис. 2.




Рисунок 2. Структура комбинированной распознающей сети, состоящей из сетей Кохонена (конкурирующая сеть) и Гроссберга (составлена авторами)

Сеть Кохонена (Kohonen's Neural Network или Kohonen's Self Organizing Feature MAP (SOFM)) предложена Кохоненом (Теуво Калеви Кохонен - академик, заслуженный профессор Академии наук Финляндии) в 1984 году.

Изначально сеть предложена в распознающем варианте. Одна из возможных модификаций состоит в добавлении к сети Кохонена сети MAXNET, что весьма важно для решаемой задачи. Выходной слой носит название слоя Гросберга и содержит три нейрона. В каталогах сетей носит название выходной сети (Outstar), представляет собой нейрон (или группу отдельных нейронов - группу звезд), управляемый весовыми коэффициентами. Предварительная обработка входных сигналов. Пусть входной сигнал обработан сетью MAXNET, то есть получена ступенчатая функция времени. Первая и основная задача - нормализация всех входных векторов. Следует отметить, что эти входы используются как на этапе обучения, так и на этапе функционирования сети (распознавания). Вторая задача, которая решается в ряде случаев, определяемых условиями выполняемой задачи, - это биполяризация компонентов входных векторов с целью более равномерного распределения входов в пространстве признаков (разработанный авторами рис. 3). Процесс биполяризации в пространстве входных сигналов представлен на разработанном авторами рис. 4.

Может быть сформулирована еще одна задача в процессе предварительной обработки входного сигнала, которая обусловлена требованиями предлагаемой методики самоорганизации и обучения слоя Кохонена. Определяется степень коррелированности входных векторов, принадлежащих к разным классам по минимальному углу β между векторами (разработанный авторами рис. 5).




Рисунок 3. Предварительная обработка входных сигналов, представленных “частотным шумовым портретом” (используется метод масок): а - процесс обработки; б - после 1 и 2 этапов обработки (составлена авторами)

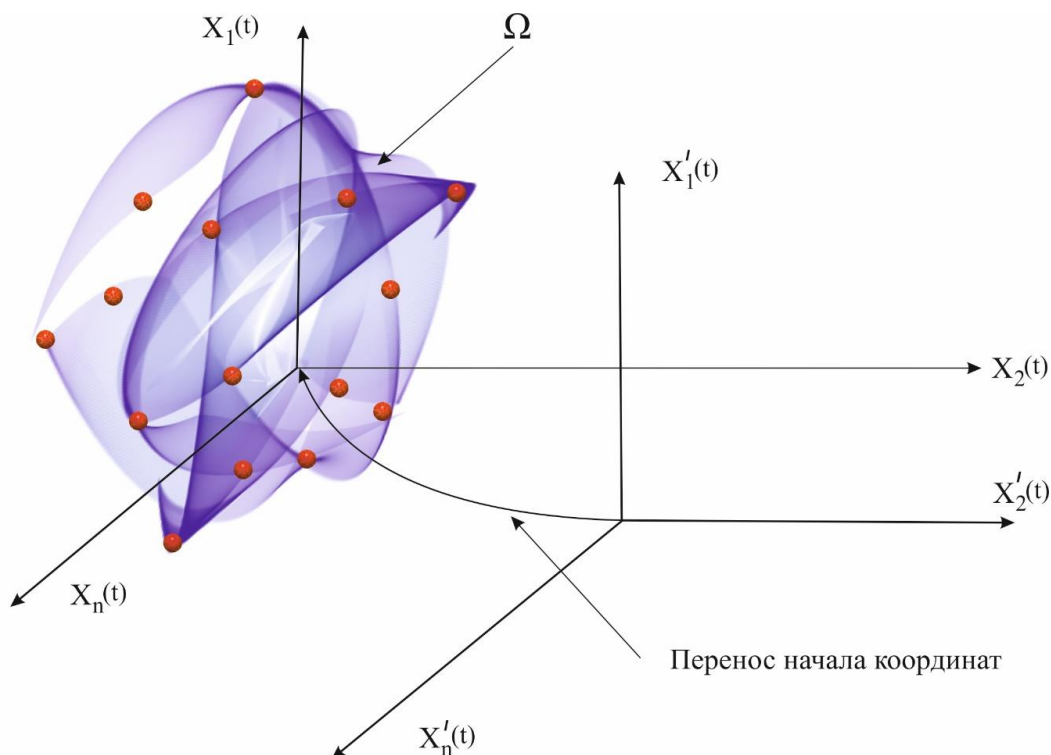


Рисунок 4. Процесс биполяризации пространства входных сигналов (точками указаны отдельные признаки): Ω - пространство признаков; $x_1'(t), \dots, x_n'(t)$ - координаты вектора признаков до нормализации; $x_1(t), \dots, x_n(t)$ - координаты вектора признаков после нормализации (составлена авторами)




Рисунок 5. Определение минимально допустимого угла β между векторами, определяющими область существования распознаваемых признаков: $\Omega_1, \dots, \Omega_i$ - область входных векторов распознаваемого объекта $N = 1, \dots, i$; β - угол между векторами, определяющими область существования категоризируемых объектов (точками отмечены "центры масс" областей) (составлена авторами)

В каждом конкретном случае решаются или все задачи или их часть (нормализация и оценка порогов близости).

Методика обучения распознающего устройства. Обучение слоя Кохонена включает:

1. архитектурную самоорганизацию (определение числа нейронов);
2. настройку синапсов (весовых коэффициентов связей) в слое Кохонена, что необходимо для предварительной классификации входных векторов;
3. формирование синапсов (весовых коэффициентов) латеральных связей, что необходимо для выделения в слое нейрона - “победителя”.

Архитектурная самоорганизация слоя Кохонена заключается в том, что на основе одного из решений известной дилеммы стабильности - пластичности, реализованной в адаптивном слое (точнее в адаптивной резонансной теории) Гросберга и Карпендера [2, 12], автономно формируется количественный состав слоя. Рассматриваемый в настоящей работе классификатор производит пороговый анализ близости очередного обучающего вектора к векторам синапсов (весовых коэффициентов), уже имеющихся в слое нейронов и если не найдется близких (по заданному порогу) векторов синапсов, то директивно увеличивается число нейронов.

Процедура самонастройки и настройки весовых коэффициентов (синапсов) сети Кохонена обычно включает в себя следующие этапы:

1. Вводится произвольное число нейронов $L = L_0$ со случайным образом нормализованными векторами синапсов, равномерно распределенными на интервале $[-1, 1]$.
2. На слой подается один из обучающих векторов входных сигналов (очевидно, что предварительно обработанный), определяются потенциалы на выходах всех нейронов и номер L^* - нейрона - “победителя”.
3. Определяется угол β^* между обучающим вектором признаков и вектором синапсов (весовых коэффициентов) нейрона - “победителя”.
4. Если выполнено условие $\beta^* < \beta$, то осуществляется настройка синапсов нейрона - “победителя” путем усреднения по всем шагам обучения, на которых он оказался нейроном - “победителем” и последующей нормализации. Если $\beta^* > \beta$, то в слой директивным порядком вводится $L+1$ нейрон, синапсом которого (весам связей) присваиваются значения компонентов соответствующего обучающего вектора.
5. Выбирается очередной входной вектор обучающей выборки и повторяются процедуры 2, 3, 4.

Следует особо отметить, что весовые коэффициенты (синапсы) латеральных связей между нейронами формируются независимо от входных векторов обучающей выборки, причем до или после архитектурной самоорганизации и настройки синапсов Кохонена. При этом выход каждого нейрона слоя Кохонена замкнут положительной связью на собственный вход и отрицательными связями на входы всех остальных нейронов слоя. Обучение слоя Гросберга является традиционным обучением с учителем и может производиться как одновременно с архитектурной самоорганизацией и настройкой слоя Кохонена по каждому входному вектору выборки, так и автоматически (после обучения слоя Кохонена). Во всех случаях правило обучения можно представить следующим алгоритмом:

$$T_{j\ell}^{\Gamma} = \sum_{S=1}^S y_{\ell}^{(S)} u_j^K (X^{(S)}), \quad \ell = 1, 2, \quad (11)$$

где: $y_{\ell}^{(S)}$ - ℓ -й компонент желаемого выходного вектора классификатора;

$u_j^K(X^{(S)})$ - выходной сигнал j -го нейрона слоя Кохонена, при обучении S -му входному вектору признаков.

Функционирование рассматриваемого распознающего устройства. Предварительно обработанный вектор входных признаков наблюдаемого объекта $\{x_i\}$ подается на вход сети и распределяется через весовые коэффициенты связей (синапсы) $\{T_{ij}^K\}$ на нейроны слоя Кохонена. Входные потенциалы нейронов

$$P_j = \sum_{i=1}^N T_{ij}^K x_i, \quad i = 1, \dots, L. \quad (12)$$

После этого слой Кохонена начинает функционировать как конкурирующая сеть с латеральными связями [2, 12]. В результате на выходе слоя формируется вектор с одним единичным компонентом, соответствующим нейрону “победителю” и с нулевыми остальными коэффициентами. Через синапсы $\{T_{ij}^\Gamma\}$ вектор входа поступает на нейроны выходного слоя Гросберга, которые функционируют согласно следующего алгоритма:

$$y_i = 1^0 \left(\sum_{j=1}^L T_{i\ell}^\Gamma u_j^K \right), \quad \ell = 1, 2, \quad (13)$$

где $1^0(\cdot)$ - функция единичного скачка.

Выводы

1. Входные вектора (признаки для распознавания) могут быть подготовлены по временным и частотным характеристикам шума распознаваемого морского объекта.
2. Наиболее подходящими структурами для решения задачи распознавания являются многослойный (не менее трех слоев) персептрон и комбинированная сеть, состоящая из слоев Кохонена на входе и выходного слоя Гросберга.
3. Подготовка данных (входных векторов) для рассматриваемых распознающих структур проводится известными классическими методами, то есть нормирование, биполяризация, определение углового расстояния между векторами признаков и т.д. Особенностью подготовки является использование метода масок на начальном этапе.
4. При классификации объектов по частотной характеристике необходимо анализировать низкочастотную, среднечастотную и высокочастотную составляющие амплитудно-частотной характеристики, так как генеральные признаки для различных типов классифицируемых объектов могут находиться в различных частотных зонах.
5. При анализе временной характеристики распознаваемых морских объектов может быть успешно использован метод Колмогорова - Хинчина, снижающий число нейронов входного слоя без потери качества распознавания.

6. Использование метода Колмогорова - Хинчина в задаче подготовки данных можно рассматривать как авторское решение, успешно примененное в задачах первичной обработки данных для нейросетевых распознающих парадигм.

ЛИТЕРАТУРА

1. Пятакович В.А., Василенко А.М. Предварительная обработка информации нейроноподобным категоризатором при распознавании образов морских объектов // Подводное морское оружие. - 2017. №1 (32). С. 31 - 34.
2. Пятакович В.А., Василенко А.М., Мироненко М.В. Технологии нелинейной просветной гидроакустики и нейро-нечетких операций в задачах распознавания морских объектов: монография - Владивосток: Издательский дом ДВФУ, 2016. - 190 с.
3. Пятакович В.А., Василенко А.М., Пащенко А.Ю. Метод выделения основных признаков морских объектов при решении задач распознавания // Проблемы и методы разработки и эксплуатации вооружения и военной техники ВМФ: Сб. статей. - Владивосток: ТОВВМУ, 2016. - Вып. 92. - С. 206 - 210.
4. Радиогидроакустическая система параметрического приема волн источников и явлений атмосферы, океана и земной коры в морской среде: пат. 2593673 РФ / М.В. Мироненко, В.А. Василенко, В.А. Пятакович; ТОВВМУ им. С.О. Макарова; 14.07.16.
5. Способ передачи информационных волн из морской среды в атмосферу и обратно: пат. 2593625 РФ / М.В. Мироненко, А.М. Василенко, В.А. Пятакович; ТОВВМУ им. С.О. Макарова; 14.07.16.
6. Пятакович В.А., Василенко А.М., Алексеев О.А. Принципы гарантированного управления безотказностью элементов нейросетевой экспертной системы классификации целей // Проблемы и методы разработки и эксплуатации вооружения и военной техники ВМФ: Сб. статей. - Владивосток: ТОВВМУ, 2016. - Вып. 92. - С. 174 - 185.
7. Пятакович В.А., Василенко А.М., Мироненко М.В. О.А. Алексеев. Операции распознавания и классификации информационных полей подводных лодок в системе освещения морских акваторий // Проблемы и методы разработки и эксплуатации вооружения и военной техники ВМФ: Сб. статей. - Владивосток: ТОВВМУ, 2016. - Вып. 92. - С. 186 - 195.
8. Мироненко М.В., Карачун Л.Э., Василенко А.М., Тихончук Е.А. Нелинейная просветная гидроакустика в гидроакустических системах освещения атмосферы, океана и земной коры, мониторинга их полей различной физической природы // Датчики и системы. - 2016. №8-9. С. 3 - 8.
9. Малашенко А.Е., Мироненко М.В., Чудаков А.И., Пятакович В.А. Просветная радиогидроакустическая система мониторинга полей атмосферы, океана и земной коры в морской среде // Датчики и системы. - 2016. №8-9. С. 9 - 13.
10. Малашенко А.Е., Мироненко М.В., Карачун Л.Э., Пятакович В.А. Дальний параметрический прием электромагнитных волн технических источников в морской среде // Датчики и системы. - 2016. №8-9. С. 14 - 18.
11. Мироненко М.В., Карачун Л.Э., Василенко А.М., Шостак С.В. Формирование просветных гидроакустических систем мониторинга с учетом корреляционных характеристик канала распространения волн // Датчики и системы. - 2016. №10. С. 21 - 26.
12. Freeman J.A., Skapura D.M. Neural Networks: algorithms, applications, and programming techniques. - Addison-Wesley Publ. Co., - 1991.

Pyatakovich Valeriy Aleksandrovich

The pacific higher naval college named after Admiral Makarov, Russia, Vladivostok
E-mail: pva.877com@mail.ru

Vasilenko Anna Mikhaylovna

The pacific higher naval college named after Admiral Makarov, Russia, Vladivostok
E-mail: kahunya@gmail.com

Mironenko Mikhail Vladimirovich

Special research bureau for automation of marine researches, far eastern branch of Russian academy of sciences
Russia, Yuzhno-Sakhalinsk
E-mail: professor@mail.primorye.ru

Neural network architectures for solving the classification problems of the sea objects' information fields, the learning methodology

Abstract. As of today, there have been developed a large number of various types of neural networks that have their own distinctive features. The most widely used are the so-called "multi-layer neural networks of direct distribution" or the multilayer perceptrons, MLP. According to experts, the "cognitive" sciences (neurosciences) and "smart" systems (neural network classifiers, neural network expert systems) are a promising area of research in solving the problems of recognition and classification of sea objects. Fuzzy reasonings in solving these problems are especially useful when there is an uncertainty in a reasoning, which makes it difficult or even excludes the use of precise quantitative methods and approaches. The analytical expressions to quantitatively evaluate fuzzy conditions of attributes belonging to a particular set (to a group of classification attributes of an object being recognized) can be obtained by applying the methods of the fuzzy sets theory. These methods allow to effectively deal with complex information processing tasks when classes to be separated have an arbitrary shape and intersect with each other, and are characterized by high accuracy and efficiency in confitions of uncertainty, by low training time and are reliable against interferences.

In this paper, based on the results of their research, the authors analyze the methods of neural network classification of images, describe the most appropriate architectures of neural networks for solving the problem of recognition of information fields of sea objects and examine the learning process.

The results of scientific research of the authors on this topic are protected by patents and published in the form of monographs and scientific articles.

The practical implementation of the system that is developed for executing the computing operations by way of neural networks on the multiprocessor neural VLSI circuits in the form of a neural network expert system for the identification and classification of measured information fields of sea objects as part of the sea waters' monitoring system will provide the ability to solve multi-functional problems of marine science and of the defense industry of the State.

Keywords: classification of sea objects; neural network architectures; fuzzy logic; membership functions; rules of inference; neural networks; neuro-fuzzy models; learning algorithm; automatic control systems