

SEABED RELIEF-BASED VESSEL POSITION FIXING WITH A NEURAL NETWORK

V. V. Deryabin

Admiral Makarov State University of Maritime and Inland Shipping,
St. Petersburg, Russian Federation

A seabed relief-based vessel position fixing system on the basis of a neural network is proposed. The neural network satisfies the conditions of the universal approximation theorem and has one hidden layer. The hidden neurons have hyperbolic tangent activation functions. The model is constructed for 1-D case that can be considered as vessel motion throw a narrow channel or fairway. A sequence of depth derivatives (in relation to the coordinate) is fed to the network input. The depth is assumed to be measured with an echo-sounder. The vessel linear coordinate registered for the last depth derivative is formed on the network output. The training set contains not only data presumably registered at the stage of preliminary depth survey but also their noise-added versions obtained with the use of a random number generator. The validation set contains the survey data only. The Adamax algorithm is implemented for the neural network training. The maximum of absolute value of the prediction error is used as a performance criterion of the net. Modeling has been conducted in Python with Tensorflow. The depth is considered to be a polynomial function of the coordinate at each path region. So, the depth derivatives can be calculated analytically. As the result it is possible to state that the neural network predicts a vessel position with acceptable accuracy even in input signal noise conditions. Moreover, the neural network architecture of the radial-basis functions has been examined, but it is not possible to achieve acceptable accuracy by using it. The conducted investigations of the influences of a mini-batch size and learning rate values on the accuracy has shown that these parameters have the significant impact and an issue of their choice remains opened and actual in the framework of the task.

Keywords: vessel, position, depth, neural network, machine learning, autonomous mode, seabed relief, calculation algorithm.

For citation:

Deryabin, Victor V. "Seabed relief-based vessel position fixing with a neural network." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admiral S. O. Makarova* 15.2 (2023): 172–179. DOI: 10.21821/2309-5180-2023-15-2-172-17.

УДК 656.61.052:527.62:004.032.26

ОПРЕДЕЛЕНИЕ МЕСТОПОЛОЖЕНИЯ СУДНА ПО РЕЛЬЕФУ ДНА ПРИ ПОМОЩИ НЕЙРОННОЙ СЕТИ

В. В. Дерябин

ФГБОУ ВО «ГУМРФ имени адмирала С. О. Макарова»,
Санкт-Петербург, Российская Федерация

Предложена модель определения места судна по рельефу дна на основе нейронной сети прямого распространения, удовлетворяющей условию универсальной аппроксимации. Рассматриваемая нейронная сеть имеет один скрытый слой с нейронами, обладающими функциями активации в виде гиперболического тангенса. Данная модель реализована для одномерного случая, соответствующего движению судна в узком канале или на фарватере. На вход сети поступает последовательность производных глубины (по координате), измеренной эхолотом. На выходе получается значение линейной координаты судна на момент определения последней производной глубины. Обучающая выборка содержит не только записи, полученные по результатам предполагаемых предварительных промеров, но и их зашумленные видоизменения, полученные при помощи датчиков случайных чисел. Контрольная выборка содержит исключительно промерные данные. Для обучения нейронной сети используется метод Adamax. В качестве критерия качества работы нейронной сети используется наибольшее значение модуля ошибки координаты на контрольной выборке. Моделирование выполнялось на языке программирования Python с библиотекой Tensorflow. Глубина аквато-

рии представлена в виде полиномиальной функции координаты, что позволяет вычислять ее производную аналитически. Проведено моделирование, результаты которого свидетельствуют об удовлетворительной точности прогноза координаты нейронной сетью в условиях наличия погрешностей входного сигнала. Выполненные исследования зависимости качества обучения от размера мини-пакета и коэффициента скорости обучения позволяют сделать вывод о том, что данные параметры оказывают существенное влияние на результат, поэтому вопрос их оптимального выбора остается нерешенным и актуальным в рамках рассматриваемой задачи.

Ключевые слова: судно, местоположение, глубина, нейронная сеть, машинное обучение, автономный режим, рельеф дна, алгоритм расчета

Для цитирования:

Дерябин В. В. Определение местоположения судна по рельефу дна при помощи нейронной сети / В. В. Дерябин // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2023. — Т. 15. — № 2. — С. 172–179. DOI: 10.21821/2309-5180-2023-15-2-172-17.

Введение (Introduction)

Определение местоположения судна по рельефу дна может использоваться для обеспечения его навигации в автономном режиме, без использования внешней информации. В качестве датчика навигационной информации при этом может выступать обычный эхолот, измеряющий только глубину под килем, который установлен на многих судах торгового флота.

В основе систем навигации по рельефу лежат алгоритмы сравнения текущей последовательности глубин, полученной по результатам измерений, с реализациями, полученными заранее на основе предварительно выполненных промеров [1], [2]. Такие алгоритмы относят к алгоритмам корреляционно-экстремальной навигации, точнее к поисковым методам. Отличительной особенностью этих методов является *требовательность* к вычислительным ресурсам для обеспечения навигации в режиме реального времени. Алгоритмы расчета взаимной корреляционной функции прямого поиска относятся к классу требовательных в вычислительном плане.

Для повышения скорости расчетов, критично важной с точки зрения навигации в режиме реального времени, представляется разработка других методов, имеющих меньшую вычислительную сложность. В качестве таковых могут рассматриваться нейронные сети, известные своей способностью к быстрым вычислениям. Идея использования нейронных сетей в задачах корреляционно-экстремальной навигации не нова. В частности, в работе [3] предлагается использовать нейронные сети для решения задачи прогнозирования временных рядов, элементами которых являются энергетические характеристики поверхности местности, с использованием которой осуществляется навигация. В работе [4] предлагается построение нейронной сети, позволяющей определять координаты судна на основе данных от магнитных и гидроакустических маячков, заранее установленных на дне. К задачам навигации по рельефу дна близки задачи моделирования геометрии рельефа. Например, в статье [5] рассматриваются нейронная сеть, решающая задачу моделирования рельефа местности при помощи расчета высоты по известным горизонтальным координатам. В статье [6] рассматриваются вопросы моделирования рельефа на основе сплайнов, которые тоже в определенной степени могут иметь нейросетевую интерпретацию. Различные подходы к решению задач батиметрической навигации содержатся также в исследованиях [7]–[9].

В указанных ранее исследованиях отсутствуют непосредственные решения задачи навигации судна по рельефу на основе нейронной сети с использованием обычного эхолота. Нейронная сеть (или близкая структура), если и используется, то лишь в качестве вспомогательного инструмента или в случае, когда для работы алгоритма нужны дополнительные технические средства. В настоящей статье предлагается нейросетевая модель определения места судна, которая непосредственно прогнозирует его координату на основе данных о рельефе дна.

Методы и материалы (Methods and Materials)

Постановка задачи. Ограничимся в работе рассмотрением одномерного случая. Пусть судно совершает движение в одномерном пространстве, двигаясь вдоль оси Ox из некоторой начальной

точки с постоянной скоростью хода V . Такая ситуация может наблюдаться во время движения вдоль оси некоторого узкого прохода или фарватера. По мере движения судно проходит последовательность точек $x_0 = 0, x_1, x_2, \dots, x_n = l$, где l — общее расстояние, пройденное судном вдоль направления оси Ox . Указанной последовательности точек соответствует некоторая последовательность глубин: $d_0, d_1, d_2, \dots, d_n$, элементы которой определены заранее по результатам гидрографических промеров. Пусть в режиме навигации на судне при помощи эхолота измеряется подмножество, состоящее из p глубин: $\{D\} = d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1}$ в некотором интервале времени. Возникает общая задача — на основе последовательности $\{D\}$ определить текущую координату x_{k+p-1} . Иными словами, необходимо по последовательности измеренных значений глубин определить координату на момент последнего поступившего измерения.

Указанная ранее общая постановка задачи может быть использована в непосредственном ее виде лишь в случае, когда уровень моря в районе плавания остается неизменным, что довольно редко наблюдается на практике. Даже в районах, где приливы практически отсутствуют, могут наблюдаться колебания уровня моря, связанные с нагонными ветровыми процессами. В связи с данным обстоятельством следует перейти к дифференциальной постановке задачи, т. е. от значений глубины к ее производной. Таким образом, необходимо решить следующую задачу: по последовательности производных глубин: $\{D'\} = d'_k, d'_{k+1}, d'_{k+2}, \dots, d'_{k+p-1}$ определить текущую координату x_{k+p-1} .

Сформулированная задача может быть решена *методом прямого поиска*, при котором полным перебором всех подпоследовательностей из общей последовательности глубин находится наиболее близкая (по заданной метрике) к измеренной реализации, для последнего элемента которой выбирается глубина. Можно записать, что $x_{k+p-1} = f(d'_k, d'_{k+1}, d'_{k+2}, \dots, d'_{k+p-1})$, т. е. текущее значение координаты является функцией текущего значения производной глубины и еще нескольких более ранних ее значений. Из теории нейронных сетей известно, что нейронные сети могут приблизить любую непрерывную функцию с любой наперед заданной точностью [10]–[12]. Таким образом, возникает задача реализации функционального преобразования $f(\cdot)$ на основе нейронной сети.

Архитектура нейронной сети. Как известно, нейронная сеть с одним скрытым слоем и полными связями обладает возможностью аппроксимировать любую непрерывную функцию с любой заданной точностью. Скрытый слой должен содержать нейроны, имеющие функции активации, которые не являются полиномами. Выходной слой имеет единственный нейрон с тождественной функцией активации. К сожалению, теоремы об аппроксимации нейронных сетей не дают ответа на вопрос о количестве нейронов, необходимых для обеспечения заданной точности. Количество нейронов зависит от вида приближаемой функции, точный вид которой, как правило, неизвестен. В связи с этим вопрос о количестве скрытых нейронов обычно решается опытным путем. На вход сети поступает вектор $d'_k, d'_{k+1}, d'_{k+2}, \dots, d'_{k+p-1}$, а на выходе получается текущее значение глубины x_{k+p-1} .

Формирование набора учебных данных. Набор учебных данных формируется следующим образом. На основе предварительно выполненных промеров глубин вдоль всего отрезка плавания оси Ox формируется генеральная последовательность $d_0, d_1, d_2, \dots, d_n$. Численным дифференцированием формируется соответствующая генеральная последовательность производных. Выбирается количество производных в подпоследовательности $\{D'\}$, равное $p - 1$. Формируется матрица входного сигнала, каждая строка которой соответствует $p - 1$ подряд идущим значениям производной глубины. Для каждого из значений производных в правом столбце матрицы соотносятся значения координат, которые и формируют *выходной вектор*.

Указанных данных, казалось бы, должно быть достаточно для настройки сети. Однако вопрос осложняется тем, что при этом отсутствует выборка для контроля обобщающих свойств сети, необходимого во избежание переобучения. Более того, в действительности производные могут быть получены с ограниченной точностью. Решить эти две проблемы можно следующим образом: к каждому элементу входной матрицы необходимо прибавить случайную погрешность, а затем вновь получившуюся матрицу присоединить снизу к исходной матрице. Выходной вектор

остаётся прежним (без погрешностей) и также присоединяется к концу первичного вектора. Процедуру необходимо повторить n_random раз. Случайная ошибка входа генерируется по закону равномерного распределения с величиной в процентном соотношении $percent_random$ от модуля производной глубины. В качестве контрольной выборки используются данные без смоделированных погрешностей, т. е. фактически записанные данные на стадии предварительного промера акватории.

Алгоритм обучения. В качестве алгоритма обучения используется Adamax — модификация алгоритма Adam [13]. Величина параметра скорости обучения выбрана равной 0,01. Все остальные параметры взяты по умолчанию в TensorFlow (v. 2.9.1). Указанный алгоритм предполагает также, что обучение может быть реализовано в мини-пакетном режиме. Размер мини-пакета был выбран равным десяти.

Результаты (Results)

Компьютерное моделирование. Для проверки идеи возможности использования нейронной сети для задачи навигации по рельефу дна выполним моделирование следующим образом. Рассмотрим движение судна вдоль оси Ox . Ось пересекает десять районов, в каждом из которых зависимость глубины от координаты представляется полиномом второй степени, коэффициенты которого индивидуальны для каждого участка и задаются случайным образом из интервалов от $-0,1$ до $0,1$ (для коэффициента первой степени) и от $-0,01$ до $0,01$ (для коэффициента второй степени). Кроме того, коэффициенты должны удовлетворять следующим условиям:

- глубина на каждом отрезке должна находиться в пределах 50–150 % от среднего уровня (10 м);
- наибольшее значение глубины на отрезке должно быть не менее 130 % по отношению к среднему уровню, наименьшее — не более 70 % по отношению к тому же уровню;
- при переходе от одного отрезка к другому должна быть обеспечена непрерывность функции, выражающей зависимость глубины от координаты x .

Указанные условия обеспечиваются моделированием. Организуется цикл, критерием выхода из которого является выполнение первых двух условий. Моделирование выполняется в Python. В результате получаются дискретные значения кусочно-полиномиальной функции глубины от координаты x .

Для каждого района выполняется 300 измерений глубин. Предполагается, что измерения выполняются в равноотстоящих точках на оси Ox . Таким образом, общая протяженность прямолинейного маршрута составляет примерно 3000 м, если предположить, что измерения глубины берутся с интервалом 1 м, что, в принципе, не обязательно, он может быть и другим, выбранным исходя из выраженности рельефа на стадии промеров. Производные глубин, формирующие входной сигнал, определяются точно, так как известен вид полинома, описывающего динамику глубины на каждом участке. Берется 100 значений производных, т. е. $p = 101$, по которым определяется глубина. Значения $n_random = 10$, $percent_random = 1$ %. Используется нейронная сеть описанной ранее архитектуры со 100 скрытыми нейронами. В качестве функции активации указанных нейронов используется гиперболический тангенс.

Процесс обучения выполняется в соответствии с алгоритмом, описанным ранее. Особенность заключается в том, что на каждой итерации фиксируется не только средний квадрат ошибки (минимизируемая функция), но и наибольшее значение модуля ошибки определения координаты x , при этом лучшее состояние сети в соответствии с данным критерием сохраняется. Общее количество итераций составляет 1000. Размер обучающей выборки составил 31911 образцов, а размер контрольной выборки — 2901. Параметр скорости обучения алгоритма Adamax был выбран равным 0,01. В качестве библиотеки обучения была выбрана Keras (Tensorflow).

По прошествии 1000 итераций наибольший модуль ошибки: 260,75 м на контрольной выборке, был достигнут после 973-й итерации. Состояние сети, соответствующее данной итерации, было сохранено как оптимальное. Средний модуль ошибки составил для указанного состояния сети 51,73 м на контрольной выборке. График процесса обучения приведен на рисунке.




График процесса обучения нейронной сети

После обучения сеть проходит дополнительное тестирование на образцах, полученных в результате прибавления к входной выборке 1 %-го уровня шума. Получены следующие результаты:

- средний модуль ошибки 53,92 м;
- наибольший модуль ошибки 323,87 м.

Рассмотрим еще одну архитектуру нейронных сетей — архитектуру на основе радиальных базисных функций (РБФ-сеть). Причем будем рассматривать такой вариант РБФ-сети, при котором центры радиальных базисных функций сами являются настраиваемыми параметрами. Повторим моделирование со всеми параметрами, которые были обозначены ранее для сети персептронного типа. Для РБФ-сети коэффициент, характеризующий степень затухания функции Гаусса при удалении от ее центра, выбран равным единице. К сожалению, результаты обучения сети не позволяют судить о ее способности прогнозировать координату судна с приемлемой точностью — на контрольной выборке наибольшее значение модуля ошибки координаты достигает 1547 м, что составляет примерно половину от общей протяженности оси канала.

Рассмотрим более подробно первый вариант нейронной сети. Изучим зависимость качества обучения от размера мини-пакета. Будем варьировать данный параметр в соответствии с приведенной последовательностью: 1, 100, 1000, 10000 и 31911. Размер мини-пакета 10 был рассмотрен ранее. Следует отметить, что размер мини-пакета 1 соответствует последовательному режиму обучения (методу стохастического градиента), а 31911 — пакетному режиму. Результаты представлены в табл. 1.

Таблица 1

Зависимость результатов обучения от размера мини-пакета

Размер мини-пакета	Наибольший модуль ошибки (шум), м	Средний модуль ошибки (шум), м
1	1433,73	733,89
10	323,87	53,92
100	289,77	33,51
1000	1150,13	466,23
10000	1140,97	372,88
31911	1486,34	724,73

Как следует из приведенной таблицы, удовлетворительные результаты определения координаты получаются при использовании размеров мини-пакета 10 и 100. При этом предельные случаи (последовательный и пакетный режимы) обнаруживают самую худшую точность.

Исследуем теперь зависимость сходимости алгоритма настройки нейронной сети от параметра скорости обучения (*learning_rate*), выбрав 100 образцов в мини-пакете, что соответствует наиболее точному варианту в соответствии с табл. 1. Результаты представлены в табл. 2.

Таблица 2

Зависимость результатов обучения от learning_rate

Значение learning_rate	Наибольший модуль ошибки (шум), м	Средний модуль ошибки (шум), м
1	774,17	130,22
1/10	978,07	261,96
1/100	289,77	33,51
1/1000	1443,0	711,06
1/10000	1457,08	724,74
1/100000	1432,12	727,58

Лучшие результаты, приведенные в табл. 2, получены для значения параметра скорости обучения 0,01, которое и было выбрано ранее для десяти образцов в мини-пакете.

Обсуждение (Discussion)

Приведенные результаты показывают, что предлагаемая модель может использоваться для определения места судна по рельефу дна. Если считать, что общая протяженность плавания составляет 3000 м, то относительная погрешность — не более 10 %. При этом учитываются возможные погрешности определения производных глубины, на основе которых сеть определяет значение координаты.

Отдельно следует рассмотреть вопрос о погрешностях определения входного сигнала сети. Во-первых, эти погрешности возникают в результате неточного определения глубин эхолотом (ошибки измерений). Во-вторых, имеют место ошибки численного дифференцирования глубины. В-третьих, ошибки возникают в результате несоответствия эталонной координатной шкалы измерений фактической, так как взять глубину в точности в той точке, где она была измерена на стадии промера, не представляется возможным. Уменьшение координатного шага измерений глубин на стадии промера, конечно, приводит к уменьшению данной составляющей ошибки. Наконец, на точность измерения входа также оказывает влияние скорость движения судна, так как временной интервал измерения глубин будет определяться именно ею. Погрешность определения скорости будет вносить погрешности в место судна, полученное на основе измерения глубин предлагаемым способом.

Рассмотренный одномерный случай имеет практическое значение, так как при добавлении второй координаты каждой последовательности глубины (или ее производной) также соответствует точка на плоскости, задаваемая уже двумя числами — координатами. Конечно, при переходе к плоскости увеличивается объем данных, повышается вероятность неоднозначностей, что будет усложнять процесс обучения для достижения заданной точности, но при этом принцип остается неизменным.

Сравнивать работу нейронной сети с классическим метрическим алгоритмом на стадии моделирования, наверное, не имеет особого смысла. Понятно, что он будет точнее нейронной сети, так как проверяются все возможные подпоследовательности на близость с измеренной. Не менее понятно и то, что при большом объеме данных метрический алгоритм будет, скорее всего, более медленным, чем нейронная сеть, или вовсе непригодным для реализации с учетом ограничений вычислительных возможностей судового компьютера. Также необходимо отметить, что точность предлагаемой модели будет ухудшаться по мере того, как меняется рельеф дна, что характерно, например, для песчаных грунтов при наличии течений. Указанное обстоятельство является существенным ограничением модели, которая может долго (без дополнительных промеров) применяться только для твердых грунтов (например, каменистых), не подверженных существенным изменениям во времени. Тем не менее применение модели для изменяющихся во времени грунтов также возможно, но точность ее будет в таком случае зависеть от частоты выполнения предварительных промеров, т. е. от того, насколько используемые промеры актуальны на момент применения модели.

Заключение (Conclusion)

Предложена модель определения места судна по рельефу дна на основе нейронной сети прямого распространения с полными связями (многослойного персептрона) для одномерного случая. Принимая на вход последовательность производных глубин, нейронная сеть прогнозирует координату судна. Результаты моделирования позволяют судить об удовлетворительной точности сети. Проведенные исследования зависимости качества обучения от размера мини-пакета и коэффициента скорости обучения позволяют сделать вывод о том, что указанные параметры оказывают существенное влияние на результат, поэтому вопрос их оптимального выбора остается открытым и актуальным в рамках решаемой задачи. Рассмотрено также решение данного вопроса на основе сетей с радиальными базисными функциями, точность которых оказалась неудовлетворительной.

В качестве дальнейших направлений исследования в первую очередь необходимо указать уменьшение ошибок системы при высоком уровне шумов входных данных. Повышение точности может быть достигнуто на каждом из этапов построения модели, а не только на стадии поиска оптимальной структуры. После того как необходимая точность будет достигнута, можно переходить к более практически значимому двумерному случаю. Другим возможным направлением исследований следует считать поиск путей перехода от производных глубин к самим глубинам для устранения ошибок численного дифференцирования. При этом модель должна учитывать возможные колебания уровня моря.

СПИСОК ЛИТЕРАТУРЫ

1. Ключева С. Ф. Синтез алгоритмов батиметрических систем навигации / С. Ф. Ключева, В. В. Завьялов. — Владивосток: Мор. гос. ун-т, 2013. — 132 с.
2. Степанов О. А. Методы оценки потенциальной точности в корреляционно-экстремальных навигационных системах: аналитический обзор / О. А. Степанов. — СПб.: ЦНИИ «Электроприбор», 1993. — 84 с.
3. Каменев А. А. Применение искусственных нейронных сетей при моделировании спектроэнергетических характеристик местности для систем технического зрения с корреляционно-экстремальными алгоритмами навигации / А. А. Каменев, А. Ю. Тонышев // СПбНТОРЭС: тр. ежегодной НТК. — 2021. — № 1(76). — С. 259–262.
4. Hou G. A Novel Underwater Simultaneous Localization and Mapping Online Algorithm Based on Neural Network / G. Hou, Q. Shao, B. Zou, L. Dai, Z. Zhang, Z. Mu, Y. Zhang, J. Zhai // ISPRS International Journal of Geo-Information. — 2019. — Vol. 9. — Is. 1. — Pp. 5. DOI: 10.3390/ijgi9010005.
5. Боронников Д. А. Нейросетевой алгоритм организации пространственных данных о рельефе местности / Д. А. Боронников, Д. В. Пантюхин, С. В. Данько // Известия МГТУ МАМИ. — 2013. — Т. 1. — № 3 (17). — С. 157–164.
6. Ююкин И. В. Сплайновая модель оперирования гридированными данными как принцип электронного картографирования топографии морского дна / И. В. Ююкин // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2022. — Т. 14. — № 5. — С. 656–675. DOI: 10.21821/2309-5180-2022-14-5-656-675.
7. Ling Y. Active Bathymetric SLAM for autonomous underwater exploration / Y. Ling, Y. Li, T. Ma, Z. Cong, S. Xu, Z. Li // Applied Ocean Research. — 2023. — Vol. 130. — Pp. 103439. DOI: 10.1016/j.apor.2022.103439.
8. Ma T. AUV robust bathymetric simultaneous localization and mapping / T. Ma, Y. Li, R. Wang, Z. Cong, Y. Gong // Ocean Engineering. — 2018. — Vol. 166. — Pp. 336–349. DOI: 10.1016/j.oceaneng.2018.08.029.
9. Norgren P. A multibeam-based SLAM algorithm for iceberg mapping using AUVs / P. Norgren, R. Skjetne // IEEE Access. — 2018. — Vol. 6. — Pp. 26318–26337. DOI: 10.1109/ACCESS.2018.2830819.
10. Haykin S. Neural Networks and Learning Machines / S. Haykin. — New Jersey: Pearson, 2009. — 936 p.
11. Hornik K. Some new results on neural network approximation / K. Hornik // Neural Networks. — 1993. — Vol. 6. — Is. 8. — Pp. 1069–1072. DOI: 10.1016/S0893-6080(09)80018-X.
12. Pinkus A. Approximation theory of the MLP model in neural networks / A. Pinkus // Acta Numerica. — 1999. — Vol. 8. — Pp. 143–195. DOI: 10.1017/S0962492900002919.
13. Kingma D. P. Adam: A method for stochastic optimization / D. P. Kingma, J. Ba // 3rd International Conference on Learning Representations. — 2015. DOI: 10.48550/arXiv.1412.6980.

REFERENCES

1. Klyueva, S. F., and V. V. Zav'yalov. *Sintez algoritmov batimetriceskikh sistem navigatsii*. Vladivostok: Mor. gos. un-t, 2013.
2. Stepanov, O. A. *Metody otsenki potentsial'noi tochnosti v korrelyatsionno-ekstremal'nykh navigatsionnykh sistemakh: Analiticheskii obzor*. Spb.: TsNII «Elektropribor», 1993.
3. Kamenev, A. A., and A. Y. Tonyshchev. "The use of artificial neural networks in modeling the spectral-energy characteristics of the terrain for vision systems with correlation-extreme navigation algorithms." *SPbNTORES: trudy ezhegodnoi NTK* 1(76) (2021): 259–262.
4. Hou, Guangchao, Qi Shao, Bo Zou, Liwen Dai, Zhe Zhang, Zhehan Mu, Yadong Zhang, and Jingsheng Zhai. "A novel underwater simultaneous localization and mapping online algorithm based on neural network." *ISPRS International Journal of Geo-Information* 9.1 (2019): 5. DOI: 10.3390/ijgi9010005.
5. Boronnikov, D. A., D. V. Pantiukhin, and S. V. Danko. "Neural network algorithm of spatial relief data organization." *Izvestiya MGTU "MAMI"* 1.3(17) (2013): 157–164.
6. Yuyukin, Igor V. "Spline model of gridded data operation as a principle of electronic mapping seabed topography." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 14.5 (2022): 656–675. DOI: 10.21821/2309-5180-2022-14-5-656-675.
7. Ling, Yu, Ye Li, Teng Ma, Zheng Cong, Shuo Xu, and Zhihui Li. "Active Bathymetric SLAM for autonomous underwater exploration." *Applied Ocean Research* 130 (2023): 103439. DOI: 10.1016/j.apor.2022.103439.
8. Ma, Teng, Ye Li, Rupeng Wang, Zheng Cong, and Yusen Gong. "AUV robust bathymetric simultaneous localization and mapping." *Ocean Engineering* 166 (2018): 336–349. DOI: 10.1016/j.oceaneng.2018.08.029.
9. Norgren, Petter, and Roger Skjetne. "A multibeam-based SLAM algorithm for iceberg mapping using AUVs." *IEEE Access* 6 (2018): 26318–26337. DOI: 10.1109/ACCESS.2018.2830819.
10. Haykin, Simon. *Neural Networks and Learning Machines*. Third Edition. New Jersey: Pearson, 2009.
11. Hornik, Kurt. "Some new results on neural network approximation." *Neural Networks* 6.8 (1993): 1069–1072. DOI: 10.1016/S0893-6080(09)80018-X.
12. Pinkus, Allan. "Approximation theory of the MLP model in neural networks." *Acta numerica* 8 (1999): 143–195. DOI: 10.1017/S0962492900002919.
13. Kingma, Diederik P., and Jimmy Ba. "Adam: A method for stochastic optimization." *3rd International Conference on Learning Representations*. 2015. DOI: 10.48550/arXiv.1412.6980.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Дерябин Виктор Владимирович —
доктор технических наук, доцент
ФГБОУ ВО «ГУМРФ имени адмирала
С. О. Макарова»
198035, Российская Федерация, Санкт-Петербург,
ул. Двинская, 5/7
e-mail: gmavitder@mail.ru, deryabinvv@gumrf.ru

INFORMATION ABOUT THE AUTHOR

Deryabin, Victor V. —
Dr. of Technical Sciences, associate professor
Admiral Makarov State University of Maritime
and Inland Shipping
5/7 Dvinskaya Str., St. Petersburg 198035,
Russian Federation
e-mail: gmavitder@mail.ru, deryabinvv@gumrf.ru

Статья поступила в редакцию 11 января 2023 г.
Received: January 11, 2023.