

ЭКСПЛУАТАЦИЯ ВОДНОГО ТРАНСПОРТА, ВОДНЫЕ ПУТИ СООБЩЕНИЯ И ГИДРОГРАФИЯ

DOI: 10.21821/2309-5180-2024-16-1-7-16

DEPTH-BASED VESSEL POSITION FIXING BY MEANS OF A NEURAL NETWORK

V. V. Deryabin

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

A depth-based vessel position fixing method on the basis of a neural network is proposed. The network takes as an input a sequence of depth values measured by an echo-sounder and predicts vessel latitude and longitude for the moment of the latest depth measurement. The neural network has a fully-connected feedforward architecture with several layers which satisfies conditions of the universal approximation in compliance with the Stone-Weierstrass theorem. The Adamax algorithm for the neural network training with controlling a maximum value of position error at each epoch is implemented. Modeling is conducted with the Python programming language and the Tensorflow library. The model surface of seabed is performed as a second-order polynomial. Training samples on the basis of virtual soundings at the coordinate net knots with the space resolution not worse than one cable are obtained. After samples obtaining the training of the neural network is conducted. A validation set is not used. Several neural networks are trained. They have different number of hidden layers and different number of neurons per each hidden layer. After training the test procedure is performed. Test samples are generated in the assumption that a vessel is moving along meridians which are not used at the stage of the preliminary soundings survey. The cases of mean and random test meridians are considered. The random meridians are obtained with a uniform random number generator. As the result, all the tested neural networks have shown approximately identical navigational accuracy which is close to the accuracy for the training set.

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

For citation:

Deryabin, Victor V. "Depth-based vessel position fixing by means of a neural network." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 16.1 (2024): 7–16. DOI: 10.21821/2309-5180-2024-16-1-7-16.

УДК 656.61.052:527.62:004.032.26

ОПРЕДЕЛЕНИЕ МЕСТОПОЛОЖЕНИЯ СУДНА ПО ГЛУБИНАМ ПРИ ПОМОЩИ НЕЙРОННОЙ СЕТИ

В. В. Дерябин

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

Предложен метод определения места судна по глубинам на основе нейронной сети, которая принимает на вход последовательность глубин, измеренных при помощи эхолота, а прогнозирует широту и долготу судна на момент измерения последней глубины. Нейронная сеть имеет архитектуру сети прямого распространения с несколькими скрытыми слоями и полными связями, удовлетворяющую условиям универсальной аппроксимации в соответствии с теоремой Стоуна – Вейерштрасса. Для обучения используется алгоритм Adamax при условии контроля наибольшего значения модуля невязки на каждой итерации. Моделирование выполнялось с использованием языка программирования Python и библиотеки Tensorflow. Модельная поверхность рельефа дна была представлена в виде многочлена второго порядка. Образцы получены на основе виртуальных измерений глубин в узлах координатной сетки с пространственным разрешением не хуже, чем один кабельтов. После сбора образцов выполнялось обучение

нейронной сети, в ходе которого не использовалась контрольная выборка. В обучении участвовало несколько нейронных сетей, отличающихся количеством скрытых слоев, а также количеством нейронов в них. После обучения было проведено тестирование, которое предполагало движение судна вдоль меридианов, в точности не совпадающих с используемыми для формирования обучающей выборки. При этом наряду с вариантом средних по долготе меридианов рассмотрен вариант выбора меридианов с использованием датчика случайных чисел равномерного распределения. В результате тестирования все рассмотренные сети показали примерно одинаковую приемлемую навигационную точность, близкую к точности, полученной на обучающей выборке.

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

Для цитирования:

Дерябин В. В. Определение местоположения судна по глубинам при помощи нейронной сети / В. В. Дерябин // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2024. — Т. 16. — № 1. — С. 7–16. DOI: 10.21821/2309-5180-2024-16-1-7-16.

Введение (Introduction)

Одной из основных задач судовой навигации является высокоточное непрерывное определение координат, успешно решаемое в настоящее время использованием спутниковых радионавигационных систем. В соответствии с хорошей морской практикой для повышения надежности обсерваций спутниковые методы должны контролироваться другими независимыми от них методами. В прибрежном плавании для этого успешно могут использоваться радиолокационные методы, в открытом море — астрономические методы и счисление. Судовое конвенционное оборудование позволяет использовать еще один класс методов определения места — *корреляционно-экстремальную навигацию по глубинам*. Предварительно записанные последовательности значений глубин и координат могут использоваться для определения места, если выполнить поиск последовательности глубины, наиболее близкой к текущей. Известно (см., например, [1] и [2]), что методы поиска в задачах корреляционно-экстремальной навигации могут предполагать наличие мощных вычислительных комплексов, способных в реальном времени решить эту задачу.

Вычислительные способности наиболее актуальны в случае, когда выполняется непосредственно поиск по базе данных. Тем не менее возможен и другой вариант, когда соответствие глубин и координат представляется некоторой структурой, не являющейся непосредственно базой данных глубин и координат. В качестве таких структур целесообразно использовать *искусственные нейронные сети*, способность которых к аппроксимации функций хорошо изучена и доказана математически [3]–[5]. Если сеть обучить, то в рабочем режиме набор данных о глубинах уже не нужно будет использовать непосредственно, так как зависимость сохранится в коэффициентах сети, и скорость вычислений будет зависеть от их количества. Функциональной зависимостью в данном случае будет являться зависимость координаты от глубины.

В настоящее время нейронные сети используются для решения задач корреляционно-экстремальной навигации (по эталонным данным). Например, в [6] предлагается построение корреляционно-экстремального метода видеонавигации, который использует изображения, предварительно проходящие процедуру сегментации при помощи нейронной сети cGAN (Conditional Generative Adversarial Network). В исследовании [7] для сегментации изображений в рамках оптической автономной навигационной системы используется нейросеть U-Net. В работе [8] нейронная сеть используется при определении координат судна по магнитным и гидроакустическим маячкам, расположенным на дне. Существуют также непосредственные решения задач навигации беспилотных летательных аппаратов по изображениям, когда на вход нейронной сети подаются изображения местности, а на выходе получаются их координаты (см., например, [9]). Для решения задач батиметрической навигации могут применяться и сплайны (см., например, [10]), которые также можно интерпретировать как нейронные сети, что показано, например, в исследовании [11]. Альтернативные решения задач батиметрической навигации можно найти в исследованиях [12]–[14].

В статьях [15] и [16] предлагаются алгоритмы определения места судна по глубинам, причем в статье [16] используется непосредственно глубина, а в [15] — ее производная. В обеих статьях рассматривается весьма ограниченный для практического использования одномерный случай. В настоящей работе рассматривается *двумерный случай*, что более соответствует реальным условиям плавания судна.

Методы и материалы (Methods and Materials)

Постановка задачи. Пусть на этапе промеров при помощи эхолота измеряются n значений глубины d на заданной акватории. Каждому такому значению глубины соответствует значение широты φ и долготы λ судна. Пусть p — количество значений глубин, которые используются для определения местоположения, т. е. используется подпоследовательность вида $\{D\} = d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1}$, где $k = 0, 1, 2, \dots, n - p + 1$, которой соответствуют подпоследовательности координат: $\{X\} = \varphi_k, \varphi_{k+1}, \varphi_{k+2}, \dots, \varphi_{k+p-1}$; $\{Y\} = \lambda_k, \lambda_{k+1}, \lambda_{k+2}, \dots, \lambda_{k+p-1}$. Предполагается, что существует функциональная зависимость вида: $\varphi_{k+p-1}, \lambda_{k+p-1} = f(d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1})$, которая может быть приближенно представлена нейронной сетью.

Следует отметить, что отображение $f(\cdot)$ может содержать неоднозначность, т. е. одной и той же последовательности глубин будут соответствовать две или более точки на плоскости. Указанная ситуация соответствует рельефу, который имеет «повторяющийся» характер, что на практике будет приводить к затруднению обучения нейронной сети. Возможна также противоположная ситуация, когда разным последовательностям глубин соответствует одна и та же точка. Действительно, в одну и ту же точку акватории можно попасть различными траекториями. Данная ситуация не должна вызывать дополнительных проблем с обучением нейронной сети.

Архитектура нейронной сети. Теория нейронных сетей позволяет использовать сеть персептронного типа с одним скрытым слоем для реализации любого непрерывного отображения по типу «вход-выход». Теоретическим обоснованием указанного утверждения может служить теорема Стоуна – Вейерштрасса. В данном случае на вход поступает вектор размерностью p , а на выходе получается вектор координат размерностью 2. Общий вид такой нейронной сети приведен на рис. 1.




Рис. 1. Общий вид архитектуры нейронной сети

В случае однослойной архитектуры и заданной функции активации скрытых нейронов (часто используется гиперболический тангенс) параметрами являются количество скрытых нейронов N , а также параметры, определяющие вид функций принадлежности. Однослойная архитектура иногда называется мелкой в отличие от архитектуры глубокой, когда нейронная сеть содержит два и более скрытых слоя. Для аппроксимации одной и той же функциональной зависимости могут использоваться как мелкие сети, так и глубокие. При этом не исключена возможность добиться

лучших результатов обучения при использовании глубокой архитектуры либо добиться примерно тех же результатов, но с использованием сети с меньшим количеством вычислительных узлов, т. е. требующей меньших вычислительных затрат. Исследования [17] и [18] содержат информацию о целесообразности использования глубоких нейросетей.

В целях настоящего исследования будем использовать несколько архитектур нейронных сетей, аналогичных приведенной на рис. 1, имеющих от одного до пяти скрытых слоев. Все скрытые нейроны таких сетей имеют функции активации в виде гиперболического тангенса. Более того, будем варьировать количество нейронов N в каждом слое сетей.

Набор учебных данных. Для генерации набора учебных данных было выполнено моделирование. Рассматривалась область на поверхности эллипсоида WGS-84, ограниченная с Севера — параллелью $34^{\circ} 26,1385' S$, с Юга — параллелью $33^{\circ} 36,0405' S$, с Востока — меридианом $76^{\circ} 29,4684' W$, с Запада — меридианом $77^{\circ} 29,9348' W$. Далее выбирался шаг по широте и долготе таким образом, чтобы пространственное разрешение по ним было не хуже, чем 1 км (185,2 м). Фактическое пространственное разрешение составило 185,17 м по широте и 183,4 м по долготе. В итоге была сформирована сетка меридианов и параллелей, в каждом узле которой глубина акватории вычисляется по следующей формуле:

$$d = 10 + 30(\varphi - \varphi_s)^2 + 200(\lambda - \lambda_w),$$

где φ_s — широта южной границы района плавания;

λ_w — долгота западной границы района плавания.

Иными словами, глубина зависит квадратично от широты и линейно от долготы. Наименьшая глубина (10 м) достигается в юго-западной точке района плавания, наибольшая — в северо-восточной. При таком подходе каждой точке (φ, λ) акватории ставится в соответствие единственное значение глубины d . Вид подводной поверхности приведен на рис. 2.




Рис. 2. Вид модельной поверхности рельефа дна

При движении вдоль меридиана глубина зависит квадратично от широты и при малом коэффициенте, учитывающем влияние долготы, возможно получение выборок, которые будут практически одинаковыми, но фактически соответствующими разным меридианам. Т. е. слабая зависимость рельефа от долготы предполагает наличие *неопределенности места по долготе*. При движении вдоль одного меридиана и слабой зависимости глубины от широты будет наблюдаться аналогичная ситуация в отношении *неопределенности места по широте*. Таким образом, коэффициенты модельной зависимости должны подбираться с учетом указанного обстоятельства.

Количество измерений глубин $p = 51$. Измерения выполняются в узловых точках, которые определены заранее с учетом желаемого пространственного разрешения. Предполагается, что гидрографическое судно (или любое другое с необходимым оборудованием) должно пройти каждую

точку и выполнить измерение глубины в ней. Вариантов обхода всех точек существует много, но для задачи батиметрической навигации важно, чтобы направление движения гидрографического судна совпадало с направлением движения судна в режиме определения места. Будем считать, что суда в заданном районе плавания движутся в основном в направлении вдоль меридианов на север. В таком случае и гидрографическое судно должно выполнять промеры в узловых точках, двигаясь вдоль меридиана. На основе этих промеров формируются последовательности, соответствующие движению на север. Схема будет «работать» и при движении в направлении на юг, если указанные последовательности рассматривать в обратном порядке. С учетом фактического разрешения по широте судно проходит 9258,5 м, набирая нужную последовательность глубин, которая впоследствии подается на вход нейронной сети, прогнозирующей его координаты.

Процедура обучения. Данная процедура была реализована в виде итерационного процесса, на каждом шаге которого определялась способность нейронной сети к прогнозу широты и долготы судна. В качестве критерия точности использовалось расстояние (модуль невязки) между прогнозируемой и эталонной точками, вычисленное вдоль геодезической линии, соединяющей указанные точки. Расстояние по геодезической линии определялось по формулам со средними аргументами. На каждом шаге работал алгоритм градиентной оптимизации (обучения) нейронной сети, в качестве которого использовался Adamax [19], представляющий собой модификацию алгоритма Adam. Параметры алгоритма использовались такие, которые были установлены по умолчанию в Keras на основе TensorFlow (v. 2.10.0). Размер минипакета был выбран равным десяти. Общее количество итераций равно 3000. Следует отметить, что алгоритм Adamax оптимизировал сеть на каждой итерации только в рамках одной эпохи.

Результаты (Results)

Было выполнено обучение нейронной сети с использованием языка программирования Python и библиотеки TensorFlow. Результаты представлены в табл. 1 в формате X/Y , где X — минимум наибольшего значения модуля невязки прогноза координат (в метрах), Y — номер итерации, на которой был зафиксирован указанный минимум. Наиболее точный результат выделен жирным шрифтом.

Таблица 1

Результаты обучения нейронной сети

Количество нейронов в каждом скрытом слое	Количество скрытых слоев				
	1	2	3	4	5
10	1135,6/2730	997,8/2709	985,9/2087	995,0/2294	917,2/2952
20	1090,7/2251	1014,2/2879	983,1/1952	911,6/2892	1004,3/2242
30	1178,1/436	1049,1/2998	1007,9/2978	1003,3/1114	929,1/2887
40	1213,2/2620	1043,7/1703	985,7/2035	980,1/2971	973,5/2851
50	1060,2/773	1066,9/961	987,2/1626	947,2/2405	974,8/2317
100	1124,7/2463	1068,9/1256	996,1/2957	992,8/1626	994,6/2200

После обучения нейронная сеть проходит тестирование, т. е. проверку работоспособности с использованием тех образцов, которые непосредственно не предъявлялись для ее обучения. Такие образцы могут появиться, когда судно идет между меридианами, на которых были выполнены предварительные промеры глубин. Более того, даже следуя точно вдоль исходного меридиана на стадии использования модели, судно не может выполнять промеры в точности в тех же точках, в которых их получало гидрографическое судно на стадии промеров. Наконец, в измерениях глубины могут присутствовать как погрешности, так и колебания уровня моря, приводящие к искажению входного сигнала нейронной сети — все зависит от того, насколько сеть чувствительна к этим эффектам.

Тестирование проводилось для двух случаев. В первом случае меридиан движения судна выбирался как средний по долготе между меридианами, на которых выполнялись виртуальные промеры, во втором — случайно по долготе из промежутка возможных значений для рассматриваемой акватории по закону равномерного распределения. Количество случайных меридианов составляет 1000.

Таблица 2

Результаты тестирования нейронной сети

Количество нейронов в каждом скрытом слое	Количество скрытых слоев				
	1	2	3	4	5
10	1136,5/1228,4	1013,1/1037,0	1048,6/1116,8	1051,3/1134,9	932,0/1002,8
20	1090,6 /1112,2	1071,3/1100,1	1035,3/1155,8	982,1/ 984,6	1007,9/1178,5
30	1178,1/1178,3	1074,1/1054,1	1070,2/1098,6	1055,2/1123,2	972,8/1006,1
40	1213,2/1214,1	1066,8/1154,2	1041,0/1025,6	1048,5/1153,6	1043,4/1073,7
50	1069,6/1104,9	1066,8/1140,1	1005,9/1005,1	1010,4/1036,6	1023,9/1107,8
100	1124,7/1124,8	1068,7/1185,3	1042,8/1069,1	1062,9/1100,9	1000,7/1081,9

Результаты представлены в табл. 2 в формате X/Y , где X — наибольшее значение модуля невязки прогноза координат для средних меридианов (в метрах), Y — для случайных меридианов (в метрах). Жирным шрифтом выделен максимально точный результат.

Обсуждение (Discussion)

Результаты тестирования показывают, что нейронная сеть способна прогнозировать координаты места судна (широту и долготу) с хорошей для навигационных целей точностью. Наибольшая ошибка (для сети с четырьмя скрытыми слоями, содержащими по 20 нейронов) не превосходит 984,6 м для акватории размером примерно 50×50 морских миль. При указанных условиях область вероятного местонахождения судна составляет приблизительно $1,2 \cdot 10^{-5} \%$ от общей площади района плавания. Для других архитектур результаты отличаются в сторону ухудшения, но незначительно.

Лучшая архитектура нейронной сети устанавливается на основании данных, приведенных в табл. 2, следующим образом. Рассматривается наибольшее из пары чисел, приведенных в ячейках таблицы. Чем меньше указанный показатель, тем лучше результат, так как действительно он характеризует наихудшую точность во всех модельных ситуациях. Например, лучший результат (932 м) достигается для архитектуры с пятью скрытыми слоями, каждый из которых содержит по десять нейронов. Однако эти результаты получены для варианта, когда выбирались средние меридианы. Для случайного характера тестовых ситуаций результат хуже и составляет уже 1002,8 м, т. е. указанное число рассматривается как итоговый результат тестирования. Схожая ситуация наблюдается и для нейронной сети, содержащей пять скрытых слоев, каждый из которых содержит по 30 нейронов.

Сравнивая данные табл. 1 и 2, можно выделить две особенности. Первая особенность заключается в том, что архитектура, которая показала самый точный результат на этапе настройки, показала лучший результат и на этапе тестирования. Вторая особенность заключается в том, что наибольший максимум ошибки для некоторых архитектур (с одним скрытым слоем) оказался одинаковым на этапах настройки и тестирования. В принципе, в этом нет ничего странного, так как берется максимум невязки, а фактические ошибки могут быть различными. Указанное обстоятельство свидетельствует о том, что если двигаться вдоль средних меридианов, то изменения в точности прогноза координат не произойдет. При этом для варианта случайных меридианов отличия фиксируются в виде табличных результатов. При случайном рассмотрении меридианов точность, демонстрируемая нейронной сетью на этапе тестирования, как правило, хуже, чем при рассмотрении средних меридианов, хотя возникают и противоположные ситуации. Однако во всех случаях расхождение в точности незначительное с точки зрения задач навигации в прибрежном плавании и открытом море.

В используемой схеме тестирования предполагается, что судно может двигаться с некоторым отклонением от тех меридианов, которые использовались при проведении предварительных промеров. В действительности, может наблюдаться ситуация, когда судно в режиме эксплуатации проходит близко к «эталонным» (промерным) меридианам, но измерения глубины выполняет не в точности в тех точках, в которых это делало промерное судно. Дело в том, что интервал, через который вы-

полняются промеры в режиме навигации, не является постоянной величиной, так как судно перемещается со скоростью, отличной от скорости движения гидрографического судна, точнее этот интервал является функцией (через коэффициент) скорости собственного и гидрографического судна. Понятно, что двигаясь со скоростью, большей промерной, интервал измерений необходимо уменьшить, и наоборот. Конечно, скорости и, как следствие, интервал измерений глубин имеют определенные погрешности, причем без учета погрешностей часов. В случае если даже можно было бы пренебречь и погрешностями интервала измерений, то существует еще дополнительная ошибка моментов измерений, связанная с тем, что необходимо начать первое измерение глубины строго в той же точке, в которой находилось гидрографическое судно на стадии предварительных промеров. Данное требование представляется весьма затруднительным на практике, так как факт вхождения судна в зону батиметрической навигации может быть определен с конечной точностью.

Ввиду указанных причин измерения глубин в режиме использования батиметрической системы навигации будут выполняться не только на промежуточных меридианах, но и на промежуточных параллелях, что не учитывает предлагаемая схема тестирования. Конечно, для учета отклонений по широте необходима модель, основанная на конкретных значениях ошибок, которые могут наблюдаться в действительности. Следует также отметить, что выбранная модель рельефа дна имеет, возможно, слишком «идеализированный» характер, предполагающий монотонные изменения глубины как при движении вдоль меридиана, так и вдоль параллели. Однако для проверки идеи двумерной батиметрической навигации на данном этапе рассмотренная модель представляется достаточной.

Предложенный алгоритм определения места судна по глубинам предполагает движение судна на этапе его использования только либо вдоль меридианов, либо вдоль параллелей, т. е. в одном из взаимно перпендикулярных направлений. В принципе, одно из них можно повернуть на любой угол относительно истинного меридиана, но требования к перпендикулярности другого направления сохраняются. В связи с этим на этапе практической реализации необходимо нанесение таких районов на электронную навигационную карту с указанием направления движения, скорости промера, т. е. необходимо принятие новых условных обозначений. Направление промеров в общем случае может быть произвольным, но при этом резко увеличивается набор учебных данных и кроме того, на практике, как правило, маршруты движения судов пролегают вдоль генеральных прямых направлений.

Заключение (Conclusion)

Проведенное моделирование показало возможность использования нейронных сетей при решении задач батиметрической навигации для двумерного случая, наиболее часто встречающегося на практике. Однако использовалась модельная поверхность рельефа дна, которая отличается в общем случае от реалистичной. Поэтому после проверки работоспособности нейронной сети на модельных данных необходимо обратиться к реальным батиметрическим данным, содержащимся, например, в электронных навигационных картах и используемым в качестве инструмента современной электронной картографии на судах. Учитывая векторный формат данных указанных карт, получить массив глубин на их основе не составит большого труда. Возможно, для некоторых районов с характерным рельефом дна данную модель уже сейчас можно использовать без каких-либо видоизменений. Очевидно, некоторые участки дна будут иметь рельеф, непригодный для навигации по глубинам (простейший пример — идеально ровное плоское дно постоянной глубины). В связи с этим необходима разработка метода оценки пригодности подводного рельефа для задач навигации по эталонным данным — следует научиться оценивать потенциальную точность такой навигации на основе данных о глубинах, которые могут быть получены как из баз данных, включая электронные карты, так и являться результатом специально выполняемых промеров акватории, если имеющихся данных о глубинах недостаточно или они ненадежные. Однако в любом случае должно быть получено наибольшее значение погрешности, которое следует ожидать ввиду «неопределенности» формы рельефа на заданной акватории.

Актуальным также является направление, связанное с учетом различного рода факторов неопределенности при создании системы определения места судна по глубинам, к которым относятся: ошибки измерений глубины, скорости и времени; колебания уровня моря сгонно-нагонного и приливного характера, а также изменения рельефа во времени.

Кроме того, в дальнейшем должны быть исследованы вопросы выбора оптимальной архитектуры нейронной сети, решающей задачу батиметрической навигации. При этом оптимальность следует рассматривать в плане быстродействия, точности, скорости настройки, простоты аппаратной и программной реализации. Указанные критерии могут противоречить друг другу. Подобного рода вопросы являются традиционными для нейронных сетей, используемых для реализации прикладных задач, решение которых вряд ли возможно только теоретическими методами и потребует, скорее всего, проведения масштабных вычислительных экспериментов.

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 «Электронприбор», 1993. — 84 с.
3. Haykin S. Neural Networks and Learning Machines / S. Haykin. — New Jersey: Pearson, 2009. — 936 p.
4. 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.
5. 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.
6. Schleiss M. Translating aerial images into street-map-like representations for visual self-localization of UAVS / M. Schleiss // Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLII-2/W13–2019. — Pp. 575–580. DOI: 10.5194/isprs-archives-XLII-2-W13-575-2019.
7. Танченко А. П. Алгоритм автономной коррекции навигационной системы беспилотного летательного аппарата на основе распознавания дорожной и речной сети / А. П. Танченко, А. М. Федюлин, Р. Р. Бикмаев, Р. Н. Садеков // Гироскопия и навигация. — 2020. — Т. 28. — № 3 (110). — С. 32–42. DOI: 10.17285/0869-7035.0038.
8. 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.
9. Harvey W. Direct Aerial Visual Geolocalization Using Deep Neural Networks / W. Harvey, C. Rainwater, J. Cothren // Remote Sensing. — 2021. — Vol. 13. — Is. 19. — Pp. 4017. DOI: 10.3390/rs13194017.
10. Ююкин И. В. Сплайновый эталон картографированной информативности корреляционно-экстремальной навигации как потенциал кибернетической ситуационной осведомленности / И. В. Ююкин // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2022. — Т. 15. — № 3. — С. 374–392. DOI: 10.21821/2309-5180-2023-15-3-374-392.
11. Fakhoury D. ExSpliNet: An interpretable and expressive spline-based neural network / D. Fakhoury, E. Fakhoury, H. Speleers // Neural Networks. — 2022. — Vol. 152. — Pp. 332–346. DOI: 10.1016/j.neunet.2022.04.029.
12. 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.
13. Ma T. AUV Bathymetric Simultaneous Localisation and Mapping Using Graph Method / T. Ma, Y. Li, Y. Gong, R. Wang, M. Sheng, Q. Zhang // The Journal of Navigation. — 2019. — Vol. 72. — Is. 6. — Pp. 1602–1622. DOI: 10.1017/S0373463319000286.
14. Rui G. Cooperative localization and bathymetry-aided navigation of autonomous marine systems: thesis / G. Rui. — Singapore: National University of Singapore, 2019. — 175 p.
15. 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: 10.21821/2309-5180-2023-15-2-172-179.
16. Дерябин В. В. Нейросетевой метод определения места судна по рельефу дна / В. В. Дерябин // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2023. — Т. 15. — № 5. — С. 723–734. DOI: 10.21821/2309-5180-2023-15-5-723-734.

17. Liang S. Why deep neural networks for function approximation? / S. Liang, R. Srikant // 5th International Conference on Learning Representations (ICLR). — 2016. DOI: 10.48550/arXiv.1610.04161.
18. Mhaskar H. When and why are deep networks better than shallow ones? / H. Mhaskar, Q. Liao, T. Poggio // Proceedings of the AAAI conference on artificial intelligence. — 2017. — Vol. 31. — No. 1. — Pp. 2343–2349. DOI: 10.1609/aaai.v31i1.10913.
19. Kingma D. P. Adam: A method for stochastic optimization / D. P. J. Kingma, 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 batimetricheskikh 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. Haykin, Simon. *Neural Networks and Learning Machines*. Third Edition. New Jersey: Pearson, 2009.
4. Hornik, Kurt. "Some new results on neural network approximation." *Neural Networks* 6.8 (1993): 1069–1072. DOI: 10.1016/S0893-6080(09)80018-X.
5. Pinkus, Allan. "Approximation theory of the MLP model in neural networks." *Acta numerica* 8 (1999): 143–195. DOI: 10.1017/S0962492900002919.
6. Schleiss, Michael. "Translating aerial images into street-map-like representations for visual self-localization of UAVs" *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLII-2/W13* (2019): 575–580. DOI: 10.5194/isprs-archives-XLII-2-W13-575-2019.
7. Tanchenko, A. P., A. M. Fedulin, R. R. Bikmaev, and R. N. Sadekov. "UAV Navigation System Autonomous Correction Algorithm Based on Road and River Network Recognition." *Gyroscopy and Navigation* 28.3(110) (2020): 32–42. DOI: 10.17285/0869-7035.0038.
8. 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.
9. Harvey, Winthrop, Chase Rainwater, and Jackson Cothren. "Direct aerial visual geolocalization using deep neural networks." *Remote Sensing* 13.19 (2021): 4017. DOI: 10.3390/rs13194017.
10. Yuyukin, Igor V. "Spline standard of mapped informativeness of correlation-extreme navigation as the potential of cybernetic situational awareness." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 15.3 (2023): 374–392. DOI: 10.21821/2309-5180-2023-15-3-374-392.
11. Fakhoury, Daniele, Emanuele Fakhoury, and Hendrik Speleers. "ExSpliNet: An interpretable and expressive spline-based neural network." *Neural Networks* 152 (2022): 332–346. DOI: 10.1016/j.neunet.2022.04.029.
12. 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.
13. Ma, Teng, Ye Li, Yusen Gong, Rupeng Wang, Mingwei Sheng, and Qiang Zhang. "AUV bathymetric simultaneous localisation and mapping using graph method." *The Journal of Navigation* 72.6 (2019): 1602–1622. DOI: 10.1017/S0373463319000286.
14. Rui, Gao. Cooperative localization and bathymetry-aided navigation of autonomous marine systems. Thesis. Singapore: National University of Singapore, 2019.
15. Deryabin, Victor V. "Seabed relief-based vessel position fixing with a neural network." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 15.2 (2023): 172–179. DOI: 10.21821/2309-5180-2023-15-2-172-179.
16. Deryabin, Victor V. "Neural network-based method for determining vessel position by seabed relief." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 15.5 (2023): 723–734. DOI: 10.21821/2309-5180-2023-15-5-723-734.
17. Liang, Shiyu, and Rayadurgam Srikant. "Why deep neural networks for function approximation?" *5th International Conference on Learning Representations (ICLR)*. 2016. DOI: 10.48550/arXiv.1610.04161.
18. Mhaskar, Hrushikesh, Qianli Liao, and Tomaso Poggio. "When and why are deep networks better than shallow ones?" *Proceedings of the AAAI conference on artificial intelligence*. Vol. 31. No. 1. 2017. 2343–2349. DOI: 10.1609/aaai.v31i1.10913.
19. 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 10 октября 2023 г.
Received: October 10, 2023.*