

DEPTH-AIDED PREDICTION OF VESSEL LATITUDE BASED ON A NEURAL NETWORK

V. V. Deryabin, A. E. Sazonov

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

A method for determining vessel latitude based on depth using a neural network is proposed. The network takes as input a sequence of depth values measured by a single-beam echo sounder and predicts the vessel's latitude at the moment of the latest depth measurement. The network has two layers. The first layer contains neurons with hyperbolic tangent activation functions. The second layer consists of a single neuron with an identical activation function. The training dataset consists of training and validation sets. The training set is formed based on a depth layer contained within an electronic navigational chart (ENC). The validation set is formed by pseudorandom variations of input samples from the training set. Each of these variations corresponds to a constant sea level variation due to measurement errors and/or fluctuations of wind and/or tidal nature. The network is trained using the Adamax optimization algorithm. The maximum absolute value of latitude prediction error for the validation set is used as a criterion for training efficiency. After training, the network is tested using test samples obtained in the same manner as for the validation set. The simulation is conducted using the Python programming language. The TensorFlow library is used for training and operating the neural network. The simulation is conducted for several network configurations, each differing in the number of hidden neurons. As a result, it has been found that the networks show a tendency to learn how to predict vessel latitude using depth values as input data. This fact allows them to be considered as promising tools for bathymetric navigation.

Keywords: vessel, latitude, depth, neural network, machine learning, autonomous mode, seabed relief, calculation algorithm, electronic chart, navigation.

For citation:

Deryabin, Victor V. and A. E. Sazonov. "Depth-aided prediction of vessel latitude based on a neural network." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 17.1 (2025): 94–104. DOI: 10.21821/2309-5180-2025-17-1-94-104.

УДК 656.61:004.032.26

ОПРЕДЕЛЕНИЕ ШИРОТЫ МЕСТА СУДНА ПО ГЛУБИНАМ ПРИ ПОМОЩИ НЕЙРОННОЙ СЕТИ

В. В. Дерябин, А. Е. Сазонов

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

Предложен метод определения широты места судна по глубине на основе нейронной сети, которая принимает на вход последовательность глубин, измеренных при помощи однолучевого эхолота и прогнозирует широту на момент измерения последней глубины. Сеть имеет два слоя. Первый слой содержит нейроны с функциями активации в виде гиперболического тангенса, второй состоит из одного нейрона, обладающего тождественной функцией активации. Набор учебных данных состоит из обучающей и контрольной выборок. Обучающая выборка формируется на основе слоя глубин, содержащегося в электронной навигационной карте. Контрольная выборка формируется путем псевдослучайных вариаций входных образцов из обучающей выборки. Каждая такая вариация соответствует постоянному изменению уровня моря вследствие ошибок измерений и/или колебаний ветрового и/или приливоотливного характера. Обучается сеть методом Adamax. Критерием эффективности обучения служит наибольшее значение модуля ошибки прогноза широты, определенное для образцов из контрольной выборки. После обучения сеть проходит тестирование на образцах, полученных аналогичным образом, как для контрольной выборки. Моделирование выполнено с использованием языка программирования Python. Для обучения и реализации работы нейронной сети используется библиотека TensorFlow. Моде-

лирование выполнено для нескольких вариантов архитектуры сети, каждый из которых отличается количеством нейронов в скрытом слое. В результате было зафиксировано, что нейронные сети имеют тенденцию к обучению их прогнозированию широты места судна по последовательности глубин, что позволяет рассматривать их в качестве перспективного инструмента для решения задач батиметрической навигации.

Ключевые слова: судно, широта, глубина, нейронная сеть, машинное обучение, автономный режим, рельеф дна, алгоритм расчета, электронная карта, навигация.

Для цитирования:

Дерябин В. В. Определение широты места судна по глубинам на основе нейронной сети / В. В. Дерябин, А. Е. Сазонов // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 1. — С. 94–104. DOI: 10.21821/2309-5180-2025-17-1-94-104. — EDN KCJFZV.

Введение (Introduction)

Алгоритмы корреляционно-экстремальной навигации (по эталонным данным) могут выступать в качестве альтернативы системам спутниковой навигации, астрономическим и радиолокационным методам. В первую очередь для целей морского судовождения представляет интерес *навигация по рельефу дна*. Указанные методы хорошо разработаны и изучены в научной литературе (см., например, [1]–[3]). Привлекательность методов навигации по рельефу дна объясняется наличием на судне однолучевого эхолота, которым оснащены все конвенционные морские суда валовой вместимостью 300 и более. Для составления эталонной карты глубин необходим приемник спутниковой системы, который также широко используется в морской навигации и гидрографии. Батиметрическая система, построенная на основе таких эталонных данных, может служить дополнительным средством определения места судна в открытом море, когда все остальные методы окажутся недоступными или будут иметь неприемлемую точность. Необходимым условием ее работы является достаточная выраженность рельефа морского дна. Следует отметить, что существует возможность работы такой системы совместно с системой счисления, используемой для уменьшения области поиска.

Подходы к решению задач навигации по эталонным данным известны достаточно давно. Одним из первых был TERCOM (Terrain Contour Matching) [4], предполагающий сравнение текущего (измеренного) профиля рельефа местности с эталонными, которые находятся в базе, созданной заранее на основе предварительных измерений, — своеобразной карте местности. Сравнение выполняется в режиме реального времени, что требует значительных вычислительных ресурсов даже несмотря на то, что область поиска может быть существенно уменьшена за счет использования приближенной навигационной системы, в качестве которой, как правило, используется счисление. Мерой близости текущего и измеренного профилей часто выбирается средний модуль отклонения (MAD — Mean Absolute Difference).

Альтернативным подходом является SITAN (Sandia Inertial Terrain-Aided Navigation) [5], представляющий собой алгоритм оптимальной оценки координат на основе фильтра Калмана, уравнение измерений которого строится на основе линеаризации глубины акватории как функции, зависящей от координат. Линеаризация выполняется в окрестности счислимой точки. Уравнение состояний может быть построено на основе статистики невязок навигационного счисления в заданном районе моря. При таком подходе в качестве вектора оцениваемых параметров выступают поправки к счислимым координатам. SITAN имеет недостаток, заключающийся в том, что при его использовании может наблюдаться расходимость процесса оценки. Указанное является наиболее вероятным, когда фактическое место судна значительно отличается от местоположения, определенного по счислению.

В связи с особенностями указанных методов возникает задача разработки алгоритма, обладающего достаточным быстродействием и исключающего возможность расходимости при любых условиях плавания. Быстрые алгоритмы, как известно, можно реализовать путем использования искусственных нейронных сетей, которые также могут рассматриваться в ряде случаев как инструменты

универсальной аппроксимации функций нескольких переменных. Возможность использования нейросетей для создания системы батиметрической навигации исследована в статьях [6]–[8]. В исследованиях [6] и [8] рассмотрен одномерный случай, когда судно движется вдоль оси некоторого направления, и возникает задача оценки расстояния (линейной координаты), пройденного вдоль указанного направления. В [7] рассмотрен двумерный случай, когда нейронная сеть, принимая на вход вектор измеренных значений глубины, прогнозирует широту и долготу судна на момент последнего измерения. Набор учебных данных для обучения сети формируется на основе моделирования рельефа дна при помощи многочлена второй степени. В статье [9] также рассматривается двумерный подход, при котором в качестве источника исходных данных выбраны официальные электронные навигационные карты (ЭНК), используемые в морской навигации в электронных картографических навигационных информационных системах (ЭКНИС). Подход с использованием ЭНК привлекателен возможностью получения эталонной батиметрической информации без проведения специальных предварительных промеров, причем указанная информация имеет статус официальной, так как содержится в слое глубин ЭНК, выпускаемых в соответствии с требованиями ИМО от имени государственных гидрографических организаций. Сложность подхода заключается в том, что глубины в ЭНК находятся в узлах нерегулярной сетки координат, и необходимо решать задачу их приведения к регулярной сетке, которая может использоваться для целей навигации.

Результаты, представленные в [9], показывают, что проблема увеличения точности работы батиметрической системы остается актуальной. Следует отметить, что не для всех рассмотренных ЭНК точность оказалась удовлетворительной. Один из путей увеличения точности может находиться в области поиска подходов к выбору архитектуры сети, выполняющей задачу прогноза координат. Вариантом такого выбора может служить переход к разделному прогнозированию широты и долготы. В настоящей статье рассматривается построение нейронной сети, прогнозирующей только широту в рамках решения задачи батиметрической навигации.

Методы и материалы (Methods and Materials)

Постановка задачи. При помощи однолучевого эхолота на этапе предварительных промеров измеряется последовательность значений глубины d на заданной акватории. Каждому значению глубины из указанной последовательности сопоставляется значение широты φ судна, измеренное с высокой точностью, например, при помощи приемника спутниковой навигационной системы. Пусть непосредственно для определения местоположения используется p значений глубины. Тогда возникает задача реализации на основе нейронной сети функциональной зависимости следующего вида:

$$\varphi_{k+p-1} = f(d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1}).$$

Здесь $k = 0, 1, 2, \dots, n - p + 1$, где $n + 1$ — количество глубин, содержащихся в общей эталонной последовательности.

Примечание. Параметр p предполагается равным, как правило, не менее двух. Однако $p = 1$ тоже возможно, когда речь идет о навигации по аномалиям рельефа. При этом аномалии рельефа (точки с существенно различимыми глубинами) должны располагаться достаточно близко друг к другу в узлах регулярной сетки. В целом, предполагается, что при любом p глубины измеряются в узлах регулярной сетки.

Следует отметить, что постановка задачи предполагает проведение специальных предварительных промеров. Если проведение таких промеров не планируется, то карту глубин можно построить в узлах регулярной сетки и на основе информации, содержащейся в гидрографических базах данных или ЭНК. При таком подходе также можно считать, что предварительные промеры выполнены и в дальнейшем использовать их для построения системы навигации по рельефу дна.

Архитектура нейронной сети. При выборе архитектуры нейронной сети необходимо в первую очередь учитывать, что она должна решать задачу приближения функций нескольких перемен-

ных. Как известно (см., например, [10] и [11]), нейронная сеть прямого распространения персептронного типа с одним скрытым слоем нелинейных нейронов может приблизить любую непрерывную функцию многих переменных с любой наперед заданной точностью. Такую сеть будем использовать в рамках настоящего исследования. Общий вид ее архитектуры представлен на рис. 1.

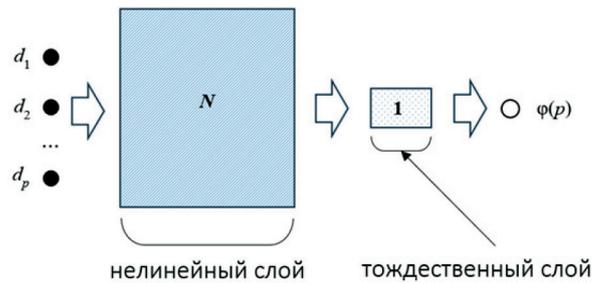


Рис. 1. Общий вид архитектуры нейронной сети

Нелинейный слой нейронной сети состоит из N нейронов, имеющих нелинейную функцию активации, в качестве которой выступает гиперболический тангенс. Выходной слой состоит из одного нейрона, имеющего тождественную функцию активации, т. е. преобразующего вход в выход без изменений. Количество скрытых нейронов N является неизвестным параметром, но именно от него зависит качество приближения многомерной зависимости. В настоящее время не существует строгих методов определения количества N в общем случае, поэтому вопрос выбора данной величины решается часто опытным путем, т. е. рассматриваются несколько архитектур с различными значениями N . Для каждой из них организуется обучение и тестирование, по результатам которого, в соответствии с выбранной метрикой, принимается решение о выборе N . В данном исследовании также варьируется число скрытых нейронов N с тем, чтобы определить степень влияния размера скрытого слоя на точность прогноза широты места судна в рамках нейросетевой батиметрической системы.

Набор учебных данных. Традиционно включает две выборки: обучающую и контрольную. Обучающая выборка непосредственно является тем исходным «учебным материалом», на основе которого решается задача оптимизации параметров нейросети, в качестве которых, как известно, выступают весовые коэффициенты и пороговые смещения. Однако в процессе обучения может наблюдаться ситуация, когда для образцов обучающей выборки будет достигнута очень хорошая точность сети, но при использовании других образцов на стадии тестирования она резко ухудшается. Иными словами, наблюдается *переобучение*. Для предотвращения его используется контрольная выборка, характеристики точности которой являются определяющими при сохранении лучшего состояния сети в процессе обучения.

В качестве источника данных о глубинах была использована ЭНК US4VA70M. При помощи утилиты командной строки ogrinfo, которая входит в пакет GDAL, был извлечен слой глубин SOUNDG. В результате был получен массив глубин на нерегулярной сетке географических координат (геодезические широта и долгота на поверхности эллипсоида WGS-84). Глубины рассматривались внутри района, ограниченного меридианами и параллелями следующим образом:

- параллелью 37°46,0' N с Севера;
- меридианом 075°29,4' W с Запада;
- параллелью 37°25,9' N с Юга;
- меридианом 075°04,1' W с Востока.

В границах указанного района была сформирована регулярная сетка глубин, имеющая пространственное разрешение примерно 1×1 милю. Угловой шаг по широте выбирался как отношение 1 мили (1852 м) к радиусу кривизны меридиана на параллели, ограничивающей район с севера. Пространственное разрешение по широте в точках, находящихся южнее северной

параллели, менее 1 мили, так как радиус кривизны уменьшается при движении от полюса к экватору. Следовательно, уменьшается и длина дуги, соответствующая одному и тому же значению центрального угла (угловому шагу). Аналогичным образом выбирается и угловой шаг по долготе, т. е. он рассчитывается как отношение одной мили к радиусу кривизны южной параллели. Понятно, что определенное таким образом значение угла-шага по долготе на северной параллели будет соответствовать меньшей длине дуги, т. е. пространственному разрешению по долготе менее 1 мили. Ввиду малых размеров района плавания указанное отличие будет незначительным, тем более что оно наблюдается в меньшую сторону.

После определения шагов по широте и долготе на итерациях вложенных циклов (внешний цикл — по долготе, внутренний — по широте) определяются значения координат узлов регулярной сетки глубин в пределах района плавания. Глубины в узлах сетки определяются *методом линейной интерполяции*. Подобный способ формирования образцов предполагает, что рекомендуемое направление для целей батиметрической навигации пролегает вдоль меридианов с юга на север.

Количество глубин, по которым вычисляется значение широты, составляет $p = 10 + 1$, т. е. в режиме сбора данных о глубинах судно проходит примерно 10 миль в направлении с юга на север, после чего выполняется вычисление нейронной сетью широты. Последняя определяется на момент последнего (одиннадцатого) измерения глубины. Следующее определение координаты выполняется по прошествии еще одной мили, и далее процесс повторяется до тех пор, пока судно не покинет район батиметрической навигации. Общая схема работы системы представлена на рис. 2. Как следует из указанной схемы, общие размеры района плавания составляют приблизительно 20×20 миль. Судно сначала в пределах первой части района плавания накапливает данные о глубинах (район 10×20 миль), что соответствует области сбора данных. Непосредственно батиметрическая навигация осуществляется в пределах второй части района плавания, размеры которого также составляют 10×20 миль.

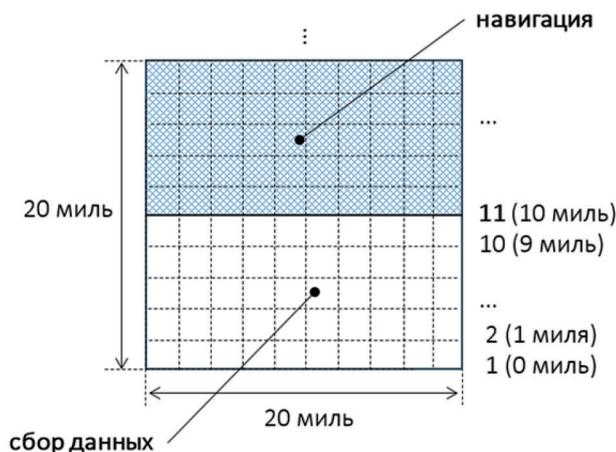


Рис 2. Схема работы системы батиметрической навигации на основе нейронной сети

В рамках небольшого участка ЭНК можно получить лишь ограниченное количество образцов, которые будут использоваться только для обучения. Для контрольной выборки необходимо сгенерировать на их основе другой набор данных. Указанное реализуется следующим образом. К каждой глубине из обучающей выборки прибавляется некоторое псевдослучайное число, подчиненное закону равномерного распределения из промежутка ± 1 м, значение широты при этом остается неизменным. Иными словами, входные образцы варьируются, а выходные — остаются неизменными. Подобное варьирование предполагает ситуации, когда фактический уровень моря в одной и той же точке акватории может быть различным на этапе измерения и навигации. Различие может быть вызвано приливами, ветровыми сгонно-нагонными явлениями, а также ошибками измерений, имеющими

постоянный характер. Таким образом, в контрольной выборке закладывается своеобразный запас устойчивости (робастности) сети, позволяющий надеяться на адекватный прогноз в тех случаях, когда форма входного сигнала несколько отличается от эталонной, т. е. той, которая представлена входными образцами из обучающей выборки.

Путем использования 100 указанных вариаций формируется контрольная выборка. В результате получено 462 образца (11 — мерных векторов глубин) для обучающей выборки, 23100 образцов для контрольной. При отрицательных вариациях глубины теоретически возможны ситуации, когда входной вектор может содержать глубину, не имеющую практического смысла. Поэтому в рамках алгоритма формирования образцов предусмотрена также проверка видоизмененных глубин на предмет соблюдения следующего условия: они должны быть не менее определенной величины (в данном случае 1 м). Новые глубины, не удовлетворяющие данному требованию, не могут быть использованы для формирования входных образцов.

Следует также отметить, что все образцы (как входные, так и выходные) проходили процедуру нормализации, т. е. приводились к промежутку от -1 до $+1$ по следующей формуле:

$$s^* = \frac{\max - \min}{s_{\max} - s_{\min}}(s - s_{\min}) + \min,$$

где $\min = -1$, $\max = +1$, s_{\max} , s_{\min} — соответственно наибольшее и наименьшее возможные значения величины s ; s^* — нормализованное, т. е. приведенное в промежуток $[\min, \max]$ значение величины s .

Как отмечалось ранее, набор учебных данных был сформирован для направления движения вдоль меридиана с юга на север. Тем не менее данный набор может быть легко конвертирован в обратное направление, а также в направления «запад – восток» и «восток – запад». Каждое из указанных направлений будет характеризоваться своим порядком следования образцов несмотря на то, что набор данных о глубинах как массив будет одним и тем же.

Предлагаемый метод формирования набора учебных данных также предполагает, что не только контрольная выборка может быть получена путем псевдослучайных изменений входных сигналов из обучающей выборки. Последняя также может быть расширена путем таких же псевдослучайных видоизменений, т. е. она будет содержать как исходные, так и полученные на их основе видоизмененные данные. При этом сеть уже непосредственно обучается ставить в соответствие один и тот же выход нескольким различным входам. Такая ситуация, как правило, наблюдается на практике ввиду колебаний уровня моря и ошибок в измерениях глубины. Следует заметить, что обратная ситуация, когда одному и тому же входу соответствует несколько различных значений широты, соответствует случаю неоднозначности рельефа, что нежелательно при использовании батиметрической системы навигации. Вопрос определения предельной степени неоднозначности рельефа, допустимой для навигации по глубинам, требует дополнительного исследования.

Псевдослучайная вариация входных образцов из обучающей выборки является не единственным способом уменьшения влияния колебаний уровня моря, вызванных в том числе ошибками измерений. Альтернативным вариантом решения указанной задачи является переход от значений глубин к их производным. Данный подход был рассмотрен в работе [8] для навигации судна по глубинам для одномерного случая, когда на вход сети подавалась последовательность не глубин, а их производных. При этом на выходе получалась координата судна. Сложность такого дифференциального подхода может заключаться в точности определения производных, вместо которых на практике используются конечные приращения.

Процедура обучения. Настройка нейронной сети выполнялась при помощи метода Adamax [12], который, в свою очередь, является разновидностью алгоритма Adam. Последний относится к классу градиентных методов. На каждой итерации величина коррекции весовых коэффициентов учитывает не только характер изменения производной ошибки, но также и квадрата производной. При обучении использовалась не только обучающая, но и контрольная выборка. Лучшее состояние сети

сохранялось на каждой итерации (эпохе) в соответствии с критерием, в качестве которого выбран максимум модуля ошибки, определяемый для образцов из контрольной выборки.

Оптимизационная задача, решаемая в процессе обучения нейронной сети, ставит целью минимизацию среднего квадрата ошибки, так как производные такой целевой функции легко рассчитываются аналитически, что необходимо для реализации алгоритма обратного распространения ошибки. Среднеквадратическая ошибка позволяет избежать грубых промахов в отличие от максимального модуля. Действительно, если в выходном образце допущена существенная ошибка, то даже при абсолютно точном прогнозе сетью ее величина будет определять максимум модуля. В случае среднего квадрата «вклад» промаха в него будет не столь заметен, так как выполняется деление на число образцов, для которых вычисляется ошибка. В рассматриваемом случае будем считать, что значение широты определяется довольно точно, в связи с чем выбор критерия в виде максимума модуля ошибки представляется вполне оправданным. Таким образом, алгоритм обучения ставит целью минимизировать среднюю квадратическую ошибку, но лучшее состояние сети определяется в соответствии с максимальным модулем. Конечно, корреляция между динамикой этих двух показателей существует, но все же она не всегда однозначная, т. е. уменьшение среднего квадрата не обязательно приведет к уменьшению максимума модуля на некотором отрезке времени обучения. Другими параметрами процедуры обучения являются число эпох-итераций (5000), размер мини-пакета (100), параметры непосредственно Adamaх (скорость обучения, параметры экспоненциального среднего, стабилизирующая константа и некоторые другие).

Тестирование. После обучения сети выполняется ее тестирование путем проверки работоспособности на образцах из тестовой выборки. Последняя формируется точно так же, как и контрольная, т. е. путем псевдослучайного изменения входных образцов из обучающей выборки при сохранении неизменными выходных. Так же, как и для контрольной выборки, предполагается изменение уровня моря в пределах ± 1 м. Использовано 1000 таких случайных видоизменений, т. е. размер тестовой выборки в 10 раз превышает размер контрольной. В качестве метрики, характеризующей качество работы нейросети, по-прежнему остается наибольшее значение модуля ошибки прогноза.

Результаты (Results)

Формирование набора учебных данных, обучение и тестирование сети были реализованы на языке программирования Python с использованием ряда необходимых библиотек (например, NumPy для работы с массивами). Непосредственно для обучения нейронной сети использовалась библиотека TensorFlow (версия 2.16.1) с интерфейсом Keras. Параметры алгоритма обучения Adamaх были взяты теми, какими они установлены по умолчанию в TensorFlow. На каждой итерации определялось наибольшее значение модуля ошибки прогноза широты для образцов из контрольной выборки. График процесса обучения для сети, содержащей 100 скрытых нейронов, приведен на рис. 3.

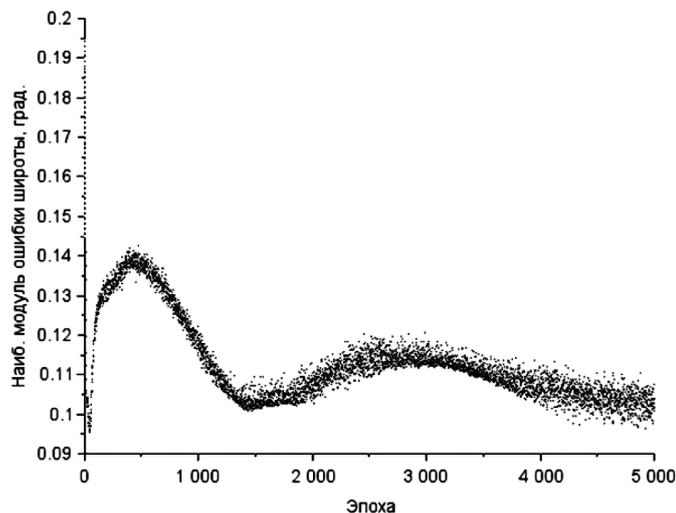


Рис 3. График процесса обучения ($N = 100$) для контрольной выборки

Результаты обучения и тестирования для архитектур с различным количеством скрытых нейронов сведены в таблицу.

Результаты обучения и тестирования нейронной сети

Количество нейронов в скрытом слое	Обучение		Тестирование	
	Наименьший максимум модуля ошибки, °	Номер итерации наименьшего максимума	Максимум модуля ошибки, °	Средний модуль ошибки, °
10	0,099473	4416	0,106388	0,033664
20	0,087745	4573	0,089818	0,02974
30	0,093003	4959	0,094822	0,030071
40	0,093104	4979	0,094726	0,029605
50	0,092017	4993	0,093677	0,029879
100	0,095417	45	0,102012	0,030728

В графе «Обучение» приведено наименьшее значение максимума модуля ошибки прогноза широты для образцов из контрольной выборки, а также номер «наилучшей» итерации, при которой это значение было зафиксировано. В графе «Тестирование» приведены максимальное и среднее значения модуля ошибки прогноза координаты, вычисленные для всех образцов из тестовой выборки после окончательного обучения нейронной сети. Значения показателей точности для обучающей выборки не приводятся.

Обсуждение (Discussion)

Результаты, представленные в таблице, показывают, что нейронная сеть после обучения имеет довольно низкую точность как на контрольной, так и на тестовой выборках. Лучший результат 0,089818° в качестве модуля погрешности определения широты соответствует примерно 5,4 мили в ошибке определения места. Средняя точность тоже невысокая, она варьируется приблизительно от 1,8 до 2 миль в ошибке определения места. При этом размеры области навигации в районе плавания составляют приблизительно 20 × 10 миль. Точность на тестовой выборке получилась хуже, чем на контрольной, что, в принципе, логично, тем более, что контрольная выборка содержит в 10 раз меньше образцов, чем тестовая, но в целом указанные отличия в точности не очень ощутимы, что свидетельствует о репрезентативности контрольной выборки, которая действительно характеризует эффективность работы нейронной сети на стадии обучения.

Несмотря на низкую точность, приведенные результаты позволяют надеяться на успешность процесса обучения. Об этом свидетельствует также кривая обучения, приведенная на рис. 3. Согласно данным, приведенным в таблице, наилучшие результаты достигаются ближе к концу обучения, кроме случая со 100 скрытыми нейронами, когда наименьший максимум модуля ошибки был зафиксирован на 45-й итерации. Поэтому можно надеяться, что результаты могут быть улучшены путем увеличения длительности обучения, т. е. максимального количества эпох. Кривая, приведенная на рис. 3, также позволяет сделать предположение, что с увеличением количества итераций может быть получена лучшая точность, чем на 45-й итерации. На графике видно, что показатель точности в районе 5000-й итерации незначительно отличается от результата, полученного на 45-й итерации. Следует отметить явно выраженный высокочастотный колебательный характер кривой обучения, приведенной на рис. 3, что подтверждает правильность подхода, предполагающего использование контрольной выборки и вычисления для нее метрики точности на каждой итерации обучения.

Отдельно следует рассмотреть вопрос влияния размера скрытого слоя на эффективность обучения. В настоящем исследовании рассмотрено 10, 20, ..., 50 и 100 нейронов скрытого слоя. Как следует из приведенной таблицы, изменение размера скрытого слоя существенным образом не меняет точность нейронной сети. Конечно, можно предположить, что при увеличении количества эпох

для архитектур с большим количеством скрытых нейронов можно получить лучшие результаты, но для 5 000 эпох ситуация именно такая. Другой интерпретацией неизменяемости точности может служить то, что нейронная сеть с большим количеством нейронов быстрее переобучается, и дальнейшее обучение теряет всякий смысл.

Создаваемая на основе нейронной сети батиметрическая система навигации имеет два режима работы. Первый режим (обучение) характеризуется настройкой нейронной сети на основе данных, полученных на регулярной сетке глубин. Второй режим (навигация) — это прогнозирование уже обученной сетью координаты (в данном случае широты). Технология формирования набора учебных данных была описана ранее. Теперь необходимо уточнить, каким образом наполняется входной вектор нейросети в режиме навигации. Рассмотрим следующую ситуацию: судно зашло в район батиметрической навигации и следует вдоль рекомендованного направления движения (в данном случае с юга на север). Нужно понять, каким образом в данном случае определяются моменты времени, в которые нужно делать промеры. Понятно, что промеры нужно делать в узлах регулярной сетки глубин, но как определить, что судно находится в узле, если местоположение его является искомой величиной. Для этого необходимо использовать счисление, на основе которого следует определять текущее приращение широты и по достижении им значения, равного дискретности модели, выполнять промер глубины. Очевидно, что точность счисления будет оказывать влияние на адекватность промеров, и, следовательно, на точность прогноза нейронной сети, поскольку даже сеть, обученная абсолютно точно, будет выдавать прогноз с ошибкой вследствие погрешностей исходных данных, содержащихся во входном векторе.

Таким образом, роль счисления остается значительной даже в рамках такого нейросетевого подхода. Для сети нет необходимости знать область поиска решения, так как она обучена для всего участка батиметрической навигации. При этом существует потребность в определении моментов времени выполнения промеров глубин, для чего и используется счисление. Более того, счисление может быть также полезно для определения текущего участка батиметрической навигации, если район плавания состоит из двух или более таких участков. В этом заключается сходство при использовании счисления с TERCOM-подходом. Если создать отдельно еще и сеть, прогнозирующую долготу, то получится своеобразная связка двух сетей, имеющих общий вход: одна сеть прогнозирует широту, другая — долготу. В результате получается местоположение судна, определенное по последовательности глубин, измеренных однолучевым эхолотом, который доступен на многих судах морского флота. На первый взгляд может показаться, что отдельный прогноз (например, широты) похож на одномерный случай, рассмотренный в статьях [6] и [8]. Однако прогноз только широты и долготы вовсе не означает, что судно движется в некотором одномерном пространстве, оно движется по поверхности эллипсоида в двумерном пространстве двух угловых координат: широты и долготы.

Заключение (Conclusion)

В результате проведенного исследования изучена возможность использования нейронных сетей для решения задач, связанных с навигацией по глубинам для судов морского флота. Несмотря на невысокие характеристики точности, достигнутые на текущий момент, нейросетевые системы прогноза широты судна по глубинам обнаруживают тенденцию к обучению, что позволяет в дальнейшем надеяться на создание работоспособных систем, которые можно будет применять на практике судовождения, используя конвенционный однолучевой эхолот. Изменение размера скрытого слоя сети не позволило заметить существенное изменение точности, что приводит к предположению, что вопрос может заключаться не только в архитектуре, но также и в параметрах алгоритма формирования набора учебных данных и настройки сети. Не слишком большие отличия характеристики точности нейросети, рассчитанные для контрольной и тестовой выборок, позволяют сделать вывод о том, что формирование контрольной выборки отвечает целям определения оптимальной в плане точности архитектуры на этапе обучения.

В качестве направления дальнейших исследований целесообразно определить следующее. Во-первых, необходимо заниматься вопросами повышения точности нейронной сети в рамках существующей архитектуры с одним скрытым слоем. Возможно, лучшие результаты могут быть получены путем изменения алгоритмов формирования набора учебных данных и / или обучения. Во-вторых, следует рассмотреть и другие, в том числе глубокие, архитектуры как в рамках сетей перцептронного типа, так и других (например, на основе радиальных базисных функций, сетей свертки). В-третьих, целесообразно вести исследования в области устранения неоднозначностей в навигации по эталонным данным в рамках нейросетевой модели определения координат места судна по глубинам. Перспективным в этом отношении является совместное использование системы батиметрической навигации с системой навигационного счисления, позволяющей определять приближенные координаты судна на основе лага и гирокомпаса. В-четвертых, необходима разработка алгоритмов оценки пригодности рельефа дна для целей навигации по глубинам, в том числе на основе нейронной сети. В связи с этим необходима также оценка потенциальной точности нейросетевой батиметрической системы для заданного района моря.

СПИСОК ЛИТЕРАТУРЫ

1. Клюева С. Ф. Синтез алгоритмов батиметрических систем навигации / С. Ф. Клюева, 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. Ma D. A robust fusion terrain-aided navigation method with a single beam echo sounder / D. Ma, T. Ma, Y. Li, Y. Ling, Y. Ben // *Ocean Engineering*. — 2023. — Vol. 286. — Pp. 115610. DOI: 10.1016/j.oceaneng.2023.115610.
4. Golden J. P. Terrain Contour Matching (TERCOM): a cruise missile guidance aid / J. P. Golden // *Image processing for missile guidance*. — 1980. — Vol. 238. — Pp. 10–18.
5. Longenbaker W. E. Terrain-aided navigation of an unpowered tactical missile using autopilot-grade sensors / W. E. Longenbaker // *Journal of Guidance, Control, and Dynamics*. — 1984. — Vol. 7. — № 2. — Pp. 175–182.
6. Дерябин В. В. Нейросетевой метод определения места судна по рельефу дна / В. В. Дерябин // *Вестник государственного университета морского и речного флота им. адмирала С. О. Макарова*. — 2023. — Т. 15. — № 5. — С. 723–734. DOI: 10.21821/2309-5180-2023-15-5-723-734. — EDN XZLJTC.
7. Дерябин В. В. Определение местоположения судна по глубинам при помощи нейронной сети / В. В. Дерябин // *Вестник государственного университета морского и речного флота им. адмирала С. О. Макарова*. — 2024. — Т. 16. — № 1. — С. 7–16. DOI: 10.21821/2309-5180-2024-16-1-7-16. — EDN LJVSHI.
8. Дерябин В. В. Определение местоположения судна по рельефу дна при помощи нейронной сети / В. В. Дерябин // *Вестник государственного университета морского и речного флота им. адмирала С. О. Макарова*. — 2023. — Т. 15. — № 2. — С. 172–179. DOI: 10.21821/2309-5180-2023-15-2-172-179. — EDN ZCDZNR.
9. Дерябин В. В. Нейросетевое решение задачи определения места судна по рельефу дна / В. В. Дерябин // *Транспортное дело России*. — 2024. — № 2. — С. 257–260. — EDN DVCMJY.
10. Haykin S. *Neural Networks and Learning Machines* / S. Haykin. — New Jersey: Pearson, 2009. — 936 p.
11. Горбань А. Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей / А. Н. Горбань // *Сибирский журнал вычислительной математики*. — 1998. — Т. 1. — № 1. — С. 11–24. — EDN PRZOML.
12. 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 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 «Elektroprigor», 1993.

3. Ma, D., T. Ma, Y. Li, Y. Ling and Y. Ben “A robust fusion terrain-aided navigation method with a single beam echo sounder.” *Ocean Engineering* 286 (2023): 115610. DOI: 10.1016/j.oceaneng.2023.115610.
4. Golden, J.P. “Terrain Contour Matching (TERCOM): a cruise missile guidance aid.” *Image processing for missile guidance* 238 (1980): 10–18.
5. Longenbaker W. E. “Terrain-aided navigation of an unpowered tactical missile using autopilot-grade sensors.” *Journal of Guidance, Control, and Dynamics* 7.2 (1984): 175–182.
6. 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.
7. 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.
8. 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.
9. Deryabin, V. “Neural net-based bathymetric solution of vessel position fixing.” *Transport business in Russia* 2 (2024): 257–260.
10. Haykin, Simon. *Neural Networks and Learning Machines*. Third Edition. New Jersey: Pearson, 2009.
11. Gorban', A. N. “Obobschennaya approksimatsionnaya teorema i vychislitel'nye vozmozhnosti neyronnykh setey.” *Siberian journal of numerical mathematics* 1.1 (1998): 11–24.
12. 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 АВТОРАХ

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
Сазонов Анатолий Ефимович —
доктор технических наук, профессор
ФГБОУ ВО «ГУМРФ имени адмирала
С. О. Макарова»
198035, Российская Федерация, Санкт-Петербург,
ул. Двинская, 5/7
e-mail: kaf_avt@gumrf.ru

INFORMATION ABOUT THE AUTHORS

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
Sazonov, Anatoly E. —
Dr. of Technical Sciences, professor
Admiral Makarov State University of Maritime
and Inland Shipping
5/7 Dvinskaya Str., St. Petersburg 198035,
Russian Federation
e-mail: kaf_avt@gumrf.ru

Статья поступила в редакцию 02 декабря 2024 г.
Received: Dec. 2, 2024.