

ЭКСПЛУАТАЦИЯ ВОДНОГО ТРАНСПОРТА, ВОДНЫЕ ПУТИ СООБЩЕНИЯ И ГИДРОГРАФИЯ

DOI: 10.21821/2309-5180-2023-15-5-723-734

NEURAL NETWORK-BASED METHOD FOR DETERMINING VESSEL POSITION BY SEABED RELIEF

V. V. Deryabin

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

A seabed relief-based vessel position fixing model on the basis of a four-layered feedforward neural network is proposed. 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 alongside fairway axis. A sequence of spot soundings is given for the network input. The linear coordinate registered for the last sounding forms the network output. The training set is formed by means of the intentional pseudorandom alteration of input samples in accordance with suspected limits of sea level variations and the constant error of its measurements. The validation set is not used. 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 with the Python programming language. The Tensorflow library is used for the creation, training and testing of the neural network. The depth is modelled as a piecewise polynomial function of the coordinate. The results of neural network testing with the use of noised input samples let to state that the neural net can determine a ship position by means of soundings with acceptable accuracy. Different combinations of the sea level error and the number of hidden neurons have been considered. For each of such combinations the network accuracy indicators have been calculated. The best results are obtained for the network with 100 hidden neurons per each layer.

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

For citation:

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.

УДК 656.61.052:527.62:004.032.26

НЕЙРОСЕТЕВОЙ МЕТОД ОПРЕДЕЛЕНИЯ МЕСТА СУДНА ПО РЕЛЬЕФУ ДНА

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 с четырьмя скрытыми слоями. Нейроны скрытого слоя обладают функциями активации в виде гиперболического тангенса. Данная модель реализована для одномерного случая, соответствующего движению судна в узком канале или вдоль оси фарватера. На вход сети поступает последовательность глубин, измеренных эхолотом, на выходе получается значение линейной координаты судна на момент измерения последней глубины. Обучающая выборка формируется путем целенаправленного случайного видоизменения входных образцов в соответствии с предположением о допустимых пределах колебаний уровня моря, а также постоянной ошибки его измерения. Контрольная выборка не используется. Для настройки свободных параметров нейронной сети применяется метод Adamax. В качестве критерия точности нейронной сети используется наибольшее значение модуля ошибки координаты на обучающей выборке. Моделирование выполнялось на языке программирования Python. Для создания, настройки и тестирования

нейронной сети также использовалась библиотека *Tensorflow*. Глубина акватории представлена в виде кусочно-полиномиальной функции координаты. Результаты тестирования нейронной сети с использованием искаженных входных сигналов позволяют сделать вывод о том, что нейронная сеть определяет место судна по глубинам с удовлетворительной точностью. Рассмотрены различные комбинации значений ошибки уровня моря и количества нейронов в каждом из скрытых слоев. Для каждой такой комбинации вычислены показатели точности, характеризующие работу нейронной сети. Наилучшие результаты получены для архитектуры, содержащей по 100 нейронов в каждом скрытом слое.

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

Для цитирования:

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.

Введение (Introduction)

В качестве автономной альтернативы спутниковых навигационных систем могут быть рассмотрены методы корреляционно-экстремальной навигации, использующие информацию о рельефе местности для определения местоположения подвижных объектов. С точки зрения судовождения практически востребованными являются методы определения судна по рельефу дна, особенно те из них, которые предполагают использование обычного эхолота, входящего в состав навигационного оборудования морских судов валовой вместимостью 300 и более в соответствии с Конвенцией СОЛАС. Как известно из [1] и [2], поисковые методы корреляционно-экстремальной навигации предъявляют, как правило, высокие требования к вычислительным ресурсам бортового компьютера, так как процедура поиска выполняется в режиме реального времени. Чем больше база исходных данных, по которой выполняется поиск, тем более быстрым должен быть поисковый алгоритм.

Проблема скорости реализации поисковых методов в корреляционно-экстремальной навигации делает актуальной задачу повышения быстродействия существующих или разработку новых алгоритмов. С точки зрения быстродействия перспективным представляется использование нейронных сетей, которые известны своим свойством приближения функций многих переменных с любой наперед заданной точностью. Указанные свойства хорошо изучены и доказаны математически [3]–[5]. При этом следует иметь в виду, что речь идет, в первую очередь, о сетях прямого распространения с полными связями, имеющими один или более скрытый слой. Предполагается, что нейронная сеть может запомнить существующую зависимость координаты от последовательности глубин, записанных через определенный интервал времени, и указанная зависимость будет сохраняться в коэффициентах сети. Таким образом, для рабочего режима нет необходимости использовать весь исходный массив данных, который имеет, как правило, очень большие объемы, замедляющие работу алгоритмов, основанных на поиске с использованием таких данных. Быстродействие нейронной сети будет определяться количеством сводных параметров (весовых коэффициентов и пороговых смещений), настраиваемых на этапе ее обучения.

Возможности нейронных сетей для решения задач корреляционно-экстремальной навигации использованы в ряде исследований. Например, в [6] нейронные сети применяются для прогнозирования временных рядов, элементы которых представляют собой энергетические характеристики рельефа местности. В статье [7] на основе нейронной сети определяются координаты места судна, при этом в качестве навигационных ориентиров выступают гидроакустические и магнитные маячки, установленные на поверхности дна. Существуют также подходы, связанные с решением схожей задачи — моделированием геометрии рельефа дна. Так, в [8] геометрия рельефа местности представляется в виде нейронной сети, определяющей высоту точки, если известны ее горизонтальные координаты, т. е. сеть аппроксимирует функцию двух переменных. В исследовании [9] рассматриваются вопросы представления участка подводной поверхности на основе двумерной сплайновой аппроксимации. Сплайны также могут иметь нейросетевую интерпретацию (см., например, [10]). Другие подходы к решению задач навигации по рельефу дна изложены, например, в работах [11]–[13].

Общим для указанных исследований является то, что их конструкции на базе нейронных сетей используются в качестве вспомогательных инструментов, не позволяющих непосредственно решать задачу прогноза координат судна на основе данных, поступающих от обычного эхолота судна. В статье [14] отмечается данный факт и предложена нейросетевая модель определения координаты судна на основе последовательности производной глубины, измеряемой эхолотом. Подход на основе производных был выбран в связи с тем, что уровень глубины акватории может меняться, а производная глубины остается вне влияния подобных изменений. Тем не менее эхолот измеряет глубину, а производная получается тем или иным методом численного дифференцирования, что добавляет погрешность и дополнительные проблемы, связанные с выбором его вида и параметров. В настоящей статье предлагается подход, не использующий численное дифференцирование глубины, но позволяющий тем не менее учитывать колебания уровня моря для акватории, где применяется батиметрическая навигация.

Методы и материалы (Methods and Materials)

Постановка задачи. Как и в статье [14], будем рассматривать одномерный случай, что соответствует движению судна вдоль оси узкого прохода или фарватера. По-прежнему, на этапе промеров при помощи эхолота измеряется генеральная последовательность глубин d , из которой определяются подпоследовательности, состоящие из p глубин вида: $\{D\} = d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1}$, где $k = 0, 1, 2, \dots, n - p + 1$, где n — общее количество измерений глубины на данном участке акватории. Также формируется генеральная последовательность координат $x_0 = 0, x_1, x_2, \dots, x_n$. Необходимо в режиме плавания судна найти в генеральной последовательности глубин подпоследовательность $\{D\}$, наиболее «похожую» на текущую, для которой значение координаты x_{k+p-1} известно. В качестве меры близости текущей последовательности глубины к записанной целесообразно выбрать расстояние Евклида. Иными словами, можно утверждать, что существует функциональная зависимость $x_{k+p-1} = f(d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1})$.

Конечно, функциональное преобразование $f(\cdot)$ может быть не всегда однозначным, что зависит от формы рельефа дна, т. е. приблизительно одинаковым последовательностям $\{D\}$ может соответствовать различное значение координаты, что соответствует повторяющемуся рельефу. Тем не менее будем считать такое поведение рельефа скорее исключением, т. е. функцию $f(\cdot)$ более или менее однозначной. Вопросы неоднозначности рассмотрим позднее. Будем искать решения реализации функционального преобразования $f(\cdot)$ на основе теории нейронных сетей, которые позволяют решать задачи приближения функций.

Архитектура нейросети. Из теории нейронных сетей известно, что нейронная сеть с одним скрытым слоем способна аппроксимировать произвольную непрерывную функцию нескольких переменных с любой наперед заданной точностью. Указанное утверждение иногда называют теоремой об универсальной аппроксимации. К сожалению, данная теорема не конструктивна, так как не дает способа нахождения архитектуры, которая обладает заданными аппроксимирующими свойствами. Основная проблема заключается в выборе количества нейронов скрытого слоя. Кроме того, выбор функций активации тоже не всегда однозначен, так как теорема об универсальной аппроксимации обязывает их лишь не быть полиномами. Как правило, для нейронов скрытого слоя используются функции активации в виде гиперболического тангенса, а для нейронов выходного слоя — тождественные функции активации (они отображают вход и выход без изменений). Проблема количества нейронов скрытого слоя осложняется также видом той функции, которая планируется быть приближенной нейронной сетью, а вид функции, как правило, остается неизвестным.

Несмотря на то, что одного скрытого слоя теоретически достаточно, чтобы выполнять аппроксимацию той или иной функциональной зависимости, его размер (количество нейронов) может оказаться слишком большим для решения данной задачи, что, в свою очередь, замедлит процесс обучения или сделает его совсем невозможным (в зависимости от имеющихся аппаратных возможностей). Как показал ряд исследований (см., например, [15] и [16]), для некоторых классов аппроксимируемых функций глубокая архитектура может обеспечить такую же точность, как и мелкая,

но при этом настраиваемых параметров (весов и порогов) будет меньше, что может, во-первых, ускорить процесс обучения и, во-вторых, позволит увеличить скорость вычислений в рабочем режиме.

Учитывая ранее изложенное, в рамках настоящего исследования, в отличие от работы [14], используется нейронная сеть не с одним, а с четырьмя скрытыми слоями, т. е. глубокая нейронная сеть. В качестве функций активации нейронов скрытых слоев использовался гиперболический тангенс. Функция активации нейрона выходного слоя тождественная. Каждый скрытый слой содержит несколько нейронов, количество которых варьируется в соответствии со следующей последовательностью: 100, 200, ..., 500. Общий вид архитектуры приведен на рис. 1.

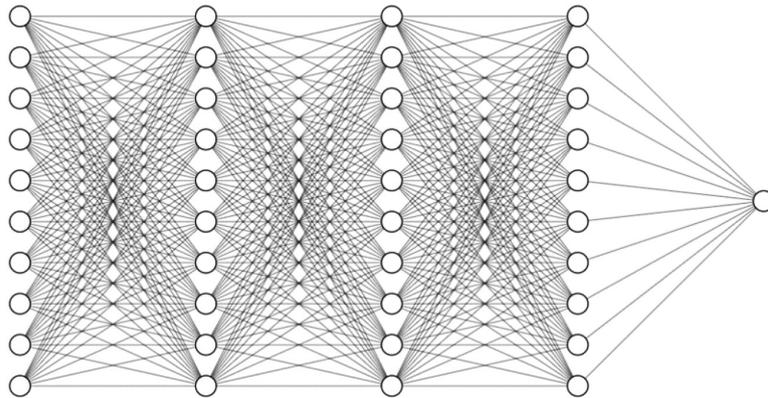


Рис. 1. Архитектура нейронной сети — общий вид (входной слой не показан)

Вектор входного и выходного сигналов определяется в соответствии с зависимостью $f(\cdot)$, т. е. на вход поступает подпоследовательность p глубин, а с выхода снимается значение координаты судна на момент взятия последней глубины.

Набор учебных данных. Как известно, для обучения нейронной сети необходимы образцы. Количество и качество образцов определяет степень точности, с которой нейронная сеть будет отображать представляемую ими функциональную зависимость. В данной ситуации количество образцов ограничено объемом общей последовательности глубин, измеренных на стадии предварительных промеров. Упорядочим образцы в виде входной матрицы F и выходного вектора Y следующим образом. Входная матрица содержит своими строками подпоследовательности глубин, выходной вектор — соответствующие им координаты. Приведем пример. Пусть 1, 2, 3, 4, 5, 6, 7, 8, 9 — последовательность глубин и $p = 5$, которой соответствует последовательность координат 10, 20, 30, 40, 50, 60, 70, 80, 90. В данном случае входная матрица имеет следующий вид:

$$F = \begin{pmatrix} 1 & 2 & 3 & 4 & 5 \\ 2 & 3 & 4 & 5 & 6 \\ 3 & 4 & 5 & 6 & 7 \\ 4 & 5 & 6 & 7 & 8 \\ 5 & 6 & 7 & 8 & 9 \end{pmatrix},$$

а выходной вектор $Y = (50 \ 60 \ 70 \ 80 \ 90)^T$. Входная матрица и выходной вектор являются удобной формой хранения данных для обучения нейронной сети. Они формируются по результатам предварительных промеров глубин на заданной акватории.

На первый взгляд, может показаться, что принцип формирования набора учебных данных определен. На самом деле, он не учитывает влияние двух факторов. Во-первых, измеренные глубины могут иметь погрешности их определения при помощи эхолота (причем как на стадии промеров, так и на стадии навигации). Во-вторых, не учитываются колебания уровня моря, которые, в свою очередь, могут быть вызваны приливными и ветровыми (сгонно-нагонными) явлениями. В принципе, результирующая погрешность может рассматриваться как сумма двух ошибок, вызванных

указанными причинами. Особенно если ошибки измерений глубины носят постоянный характер. Например, погрешность измерения всех глубин на этапе промера составляет $-0,1$ м, на этапе навигации — $+0,5$ м, а уровень моря увеличился на 1 м. В итоге в режиме навигации придется иметь дело с последовательностью, каждый элемент которой будет на 1,6 м больше, чем он был зафиксирован тогда, когда выполнялись предварительные промеры.

Во избежание указанных проблем предлагается следующий прием. Необходимо сделать r дубликатов матрицы F . Дубликат представляет собой сумму исходной матрицы F с матрицей, каждый элемент которой содержит случайное число, принимающее значение по закону равномерного распределения из промежутка $[-1; +1] \cdot e$, где e — ошибка уровня глубины. Как отмечалось ранее, e включает как действительные колебания уровня моря, так и постоянную ошибку измерений. С каждым дубликатом входной матрицы F выходной вектор Y рассматривается без изменений. В результате набор учебных данных расширяется в r раз. Он не содержит «чистые» входные образцы, а только измененные случайным образом. Предполагается, что создание видоизмененных входных образцов с сохранением выходных без изменений должно обеспечить устойчивость нейронной сети к колебаниям уровня моря. Параметрами алгоритма формирования учебных данных являются два числа: r и e .

Следует заметить, что предлагаемый метод формирования набора учебных данных не предполагает наличия контрольной выборки, используемой для контроля обобщающих свойств сети в процессе обучения. Указанное обстоятельство может показаться странным. Дело в том, что причиной переобучения сети является малый объем учебных данных по отношению к ее свободным параметрам (весовым коэффициентам). Сеть просто «запоминает» данную конкретную выборку и для нее она работает очень хорошо, но если выборку несколько видоизменить, то сеть начинает плохо работать. Предлагаемый метод как раз и предполагает видоизменения исходной выборки, поэтому при условии большого количества таких видоизменений можно надеяться, что эффект от переобучения не окажет существенного влияния на качество работы нейросети. Конечно, вопрос выбора r может быть решен лишь опытным путем.

После получения обучающих примеров по типу «вход-выход» они были нормализованы, т. е. сделано так, чтобы они принимали значения от -1 до $+1$. Наибольшее значение глубины для масштабирования определяется как сумма наибольшего значения глубины из модельной выборки и величины e . Наименьшее — как разность наименьшего значения глубины и величины e . Наименьшее значение координаты для масштабирования выбрано равным нулю. Наибольшее — наибольшему значению координаты, достигнутому на момент окончания плавания судна. Выбор промежутка масштабирования $[-1; 1]$ не имеет точного математического обоснования несмотря на то, что такой промежуток часто используют некоторые среды моделирования по умолчанию, если скрытые нейроны имеют в качестве функции активации гиперболический тангенс. Дело в том, что тангенс гиперболический имеет областью своих значений отрезок $[-1; 1]$, т. е. выход любого нейрона принадлежит указанному отрезку, и от каждого входа также поступает значение от -1 до 1 , что придает единообразие, если совокупность входных сигналов рассматривать (что иногда и делают) как некоторый входной слой.

Алгоритм обучения. Для обучения нейронных сетей применяют методы нулевого, первого и второго порядков. Методы нулевого порядка применяются, когда нет возможности вычислить градиент целевой функции ошибки. Подобная ситуация возникает, например, когда функция ошибок не имеет аналитически выраженных производных по отношению к весам сети. Методы первого порядка основаны на вычислении градиента. Методы второго порядка используют дополнительно информацию, выражающуюся вторыми производными минимизируемой целевой функции. Как правило, сходимость методов нулевого порядка небыстрая, да и градиент известен, поэтому использовать их особого смысла нет. Методы второго порядка эффективны, но предъявляют повышенные требования к оперативной памяти, так как предполагают пакетный режим обучения. В связи с изложенным наиболее оптимальными представляются методы первого порядка. В библиотеке TensorFlow (v. 2.10.0), точнее в ее надстройке Keras, имеется несколько алгоритмов обучения, начиная от простейшего стохастического градиента (SGD), заканчивая более совершенными (Adagrad,

RMSprop, Adadelta, Adam). Алгоритм SGD использует в общем случае идею инерционности, позволяющей преодолевать локальные минимумы. Методы Adagrad и RMSprop используют идею индивидуальной настройки каждого коэффициента нейронной сети в зависимости от поведения градиента. В алгоритмах Adadelta и Adam использованы обе указанные идеи.

Известна также модификация алгоритма Adam – Adamax [17], который хорошо себя проявил при решении задачи обучения в [14], поэтому был выбран в роли алгоритма настройки нейронной сети. Коэффициент скорости обучения (`learning_rate`) установлен 0,001, что соответствует значению по умолчанию в TensorFlow. Остальные параметры алгоритма обучения (коэффициенты забывания для производной ошибки и ее квадрата и др.) также взяты по умолчанию. Так как алгоритм предполагает реализацию в минипакетном режиме, то размер мини-пакета выбран равным 100. Следует отметить, что Adamax рассматривается как метод оптимизации коэффициентов нейронной сети. В качестве целевой функции, подлежащей минимизации, для него выбран традиционный средний квадрат ошибки, который очень удобен для вычисления производных на этапе реализации алгоритма обратного распространения. Однако указанный показатель не исключает выбросов в виде больших ошибок прогноза, так как обеспечивает лишь удовлетворительную среднюю точность. В задаче прогноза координаты судна подобного рода ошибки недопустимы и более привлекательным представляется такой показатель как наибольшее значение модуля ошибки. Однако наибольший модуль ошибки минимизировать в рамках алгоритма обратного распространения затруднительно, так как возникают сложности определения производной такой целевой функции. Тем не менее контролировать данный показатель все же можно, например, после определенного количества итераций, на каждой из которых настройка нейронной сети осуществляется в соответствии с критерием средней квадратической ошибки в рамках Adamax.

Таким образом, полная процедура обучения включает два процесса: собственно настройку коэффициентов нейронной сети методом Adamax и периодический контроль точности прогноза в соответствии с критерием наибольшего значения модуля ошибки. Как отмечалось ранее, критерий рассчитывается для той же выборки, которая используется для настройки, так как контрольная выборка не формируется.

Результаты (Results)

Компьютерное моделирование проводится в целях проверки работоспособности изложенных ранее теоретических предположений. Рассматривается движение судна с постоянной скоростью вдоль прямой оси некоторого маршрута, пересекающей 20 участков, на каждом из которых глубина изменяется в зависимости от координаты как многочлен второй степени. При этом для каждого участка задаются случайным образом свои коэффициенты многочлена с учетом следующих ограничений:

- минимальная глубина на каждом участке обязательно должна достигнуть значения диапазона от 50 до 70 % среднего уровня глубины (принимается равным 10 м);
- максимальная глубина на каждом участке обязательно должна достигнуть значения диапазона от 130 до 150 % среднего уровня глубины;
- глубина на границах участков не меняется скачкообразно, хотя такое поведение и может наблюдаться в действительности.

Коэффициенты полинома, моделирующего зависимость глубины от координаты, выбираются случайным образом по закону равномерного распределения из диапазона от $-0,01$ до $0,01 \text{ м}^{-1}$ (для старшего коэффициента) и от $-0,1$ до $0,1$ (для линейного коэффициента). Выбор осуществляется для каждого сегмента маршрута с проверкой выполнения указанных ранее условий, касающихся экстремальных значений глубины. Если условия для рассматриваемого сегмента не выполняются, то происходит новый выбор значений коэффициентов до тех пор, пока глубина не будет изменяться в желаемых пределах. Иными словами, случайный выбор коэффициентов моделирующего полинома происходит на итерациях бесконечного цикла, критерием выхода из которого служат указанные условия, касающиеся экстремальных значений глубины.

Моделирование выполняется в среде Spyder в комбинации с Python. В итоге получается генеральная выборка координаты судна и генеральная выборка глубины. Для формирования набора

учебных данных используется $p = 301$ значений глубин, т. е. нейронная сеть принимает на вход последовательность, состоящую из 301 измеренных глубин, и прогнозирует значение координаты на момент последнего измерения глубины. Предположим, что измерения поступают через 1 м, тогда выбранное число точек соответствует длине траектории 300 м. По наблюдениям глубины за последние 300 м сеть выдает оценку координаты на текущий момент времени. Образцы формируются с использованием следующих значений параметров: $r = 500$ и $e = 1, 2, \dots, 5$ м. Таким образом, создается 500 дубликатов входной матрицы F , а уровень ошибки принимает различные значения.

Обучение нейронной сети выполнялось на протяжении 1000 эпох (циклов коррекций), на каждой из которых контролировался максимум модуля ошибки на обучающей выборке. Лучшее состояние сети сохранялось в соответствии с указанным критерием. График процесса обучения (для $e = 5$ м) приведен на рис. 2, а. Оптимальное значение критерия (22,2 м) было достигнуто на 724 эпохе (итерации). Как видно из рисунка, поведение указанного критерия имеет скачкообразный мало предсказуемый характер, т. е. наряду с низким уровнем ошибки, который наблюдается начиная примерно с пятидесятой итерации, имеет место резкий рост уровня, причем подобного рода скачки сохраняются до конца обучения. Совершенно иначе ведет себя минимизируемая в рамках Adama целевая функция — половина среднего квадрата ошибки. Соответствующий график представлен на рис. 2, б, откуда видно, что кривая обучения имеет преимущественно плавный, асимптотический характер, хотя наименьшее значение достигается на 908 итерации, а не на 1000. Расхождение кривых обучения для различных критериев точности подтверждает правильность идеи контроля максимального модуля ошибки на каждой итерации, так как для одного и того же состояния нейросети различие критериев точности может быть очень большим, и ориентироваться только на традиционную кривую обучения (см. рис. 2, б) неправильно.

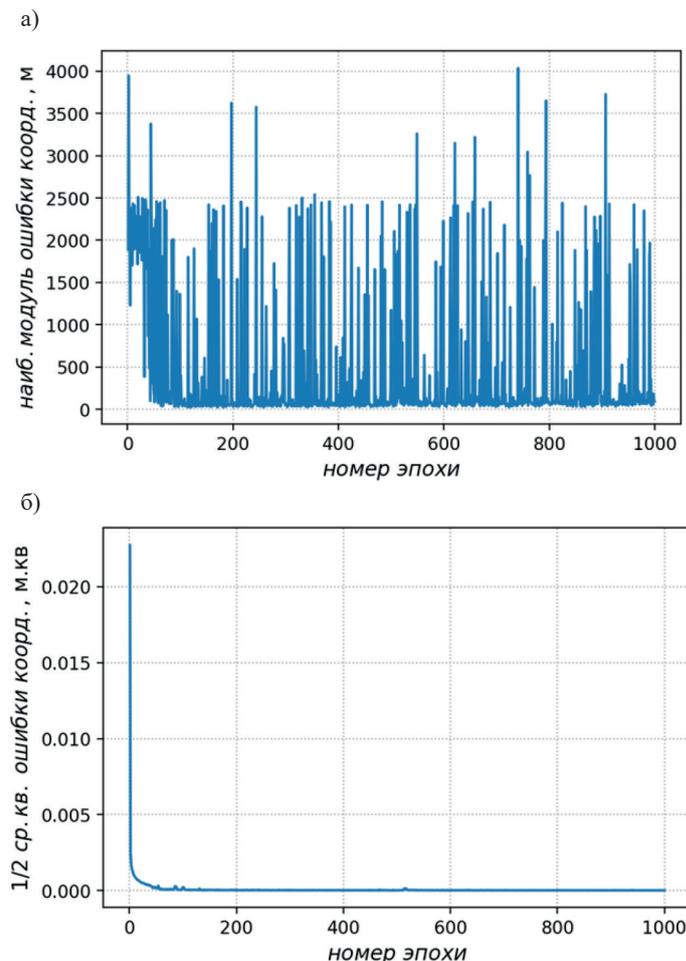


Рис. 2. Графики процесса обучения: а — наибольший модуль ошибки; б — половина среднего квадрата ошибки

После обучения нейронная сеть проходила тестирование на образцах, которые не были включены в обучающую выборку, но были сформированы точно также, с использованием случайного значения e . Количество тестовых ситуаций — 1000. Результаты сведены в таблицу, в которой приводятся характеристики точности нейронной сети в формате X / Y , где X — среднее значение модуля ошибки прогноза координаты (в метрах), а Y — наибольшее значение модуля ошибки прогноза координаты (в метрах).

Результаты обучения нейронной сети

Ошибка уровня моря e , м	Число нейронов в каждом скрытом слое				
	100	200	300	400	500
1	3,0/23,8	3,1/73,4	3,5/169,4	3,9/202,5	6,2/172,7
2	1,9/17,0	2,5/28,6	3,7/37,7	2,9/43,3	3,8/85,1
3	2,0/ 15,0	1,9/31,0	3,5/49,9	4,3/60,0	4,0/75,0
4	1,4/19,3	2,8/25,8	2,6/30,8	3,6/47,8	5,5/51,2
5	2,1/17,9	2,3/25,8	3,6/41,9	3,9/53,2	5,6/54,4

Характеристики точности приводятся с округлением до одного десятичного разряда после запятой. Жирным шрифтом выделены лучшие результаты для каждого значения ошибки уровня e .

Обсуждение (Discussion)

Результаты, приведенные в таблице, показывают, что нейронная сеть успешно справляется с поставленной изначально задачей — прогнозирует координату судна с хорошей точностью в условиях колебания уровня моря и постоянных ошибок измерений, причем в смысле наибольшего значения модуля ошибки. Например, промеры проводились при одном уровне моря, и даже если он изменяется на ± 5 м, то нейронная сеть все равно с хорошей точностью прогнозирует координату. Погрешность 17,9 м при общей протяженности маршрута около 6000 м представляется довольно точным результатом. Относительная погрешность получается не более 0,3 %. Средняя точность вообще находится на практически идеальном уровне. При этом не используются производные глубины, а только ее непосредственные значения, и проблема ошибок численного дифференцирования исчезает.

Увеличение количества нейронов в скрытых слоях не приводит к увеличению точности: она как правило, падает. Указанное справедливо для обеих характеристик точности. Данное обстоятельство может быть объяснено тем, что количество образцов слишком мало в соотношении с количеством настраиваемых параметров сети. В связи с этим целесообразно увеличить количество образцов, например, используя 1000 дубликатов матрицы F вместо 500. Для архитектуры с количеством нейронов 100 в каждом скрытом слое процесс обучения был повторен для ошибки уровня $e = 5$ м. В результате тестирования характеристики точности составили 1,9/21,1 м, что незначительно отличается от данных таблицы с учетом того, что уровень ошибки при тестировании был занижен и составлял $e = 4$ м. Возможно, для нового объема учебных данных необходимо больше циклов обучения. Их количество было также увеличено до 2000, что не позволило, однако, улучшить показатели точности работы нейронной сети.

Неудавшаяся попытка увеличения точности нейронной сети путем увеличения объема учебных данных и эпох справедлива только для архитектуры, каждый скрытый слой которой содержит по 100 нейронов. Возможно, применение указанных действий для сетей с большим количеством нейронов будет иметь более видимый эффект, но ввиду хорошей точности для архитектуры с наименьшим числом нейронов, аналогичные эксперименты для других вариантов не проводились. Следует также отметить, что после каждого варианта обучения фиксировались и показатели точности для так называемой *идеальной выборки*, т. е. для которой использовались глубины, измеренные эхолотом на этапе предварительных промеров. Как отмечалось ранее, для настройки использовалась не идеальная выборка (сама входная матрица F), а только ее зашумленные дубликаты. Тем не менее показатели точности для нее находились приблизительно на уровне тех, которые приведены в соответствующих ячейках таблицы результатов.

Исходя из практических соображений, возникает закономерный вопрос: «какую же из сетей, приведенных в таблице, необходимо брать для использования?». В первую очередь, необходимо определиться с возможным уровнем ошибки e исходя, например, из статистической информации для данного района моря, а также предполагаемого уровня погрешностей измерений, затем выбрать сеть с тем количеством нейронов, которое обеспечивает наименьшую максимальную ошибку прогноза. В данном случае для любого уровня ошибки e наилучшая точность обеспечивается нейронной сетью, каждый скрытый слой которой содержит по 100 нейронов. Можно, конечно, взять конфигурацию сети с максимальным уровнем $e = 5$ м, так как точность для каждого e примерно одинакова, но 1000 тестовых ситуаций более низкий уровень e покрывают более плотно, т. е. чем ниже e , тем выше достоверность тестирования при неизменном количестве тестовых ситуаций. Таким образом, следует выбирать уровень ошибки e исходя из реально возможной величины колебаний уровня моря и ожидаемой предельной ошибки получения глубины.

Анализируя применимость предлагаемого метода батиметрической навигации, необходимо учитывать ряд обстоятельств. Во-первых, метод будет хорошо работать только для тех участков акватории, подводный рельеф которых имеет уникальный, ярко выраженный и неповторяющийся характер. Действительно, навигация по глубинам с идеально плоским горизонтальным дном вряд ли возможна. Во-вторых, метод навигации по глубинам будет работать, если текущая форма рельефа дна не меняется существенным образом в промежутках времени между промерами. Например, для песчаных грунтов в районах с интенсивными течениями промерные работы должны производиться часто в отличие от каменистых и скалистых форм подводного рельефа. В-третьих, предлагаемый метод определения по глубинам, в принципе, должен работать без обязательной процедуры предварительных промеров как таковой, выполняемой специально для батиметрической навигации. Одним из вариантов является возможность использования информации о глубинах, содержащихся, например, в официальных электронных навигационных картах (ENC), точнее, в слое объектов SOUNDG. Другим вариантом является использование различных цифровых моделей рельефа дна [18], например, GEBCO, ETOPO, IBCAO и др., что, скорее, подходит для научно-исследовательских, а не навигационных целей. При этом взятие промеров будет моделироваться в соответствии с выбранной дискретностью. Точечные глубины будут, как правило, располагаться на некотором расстоянии от предполагаемых точек «виртуального» промера в узлах неравномерной сетки, в связи с чем необходимо применять соответствующие методы интерполяции, выбор которых не представляется всегда однозначным.

Необходимо указать ошибки, которые могут возникать в процессе использования предлагаемой батиметрической навигационной системы.

Во-первых, изменяющиеся во времени погрешности измерений будут искажать выборку, делая ее не похожей на ту, которая была зарегистрирована на этапе предварительных промеров. Причем влияние будут иметь именно изменяющиеся погрешности, так как постоянные учтены в величине e на этапе формирования обучающей выборки. Во-вторых, погрешность будет вносить несоответствие скоростей движения промерного и использующего систему судна. Конечно, судно, использующее батиметрическую навигационную систему, не обязано двигаться со скоростью промерного, так как всегда можно ввести масштабный коэффициент, изменяющий частоту регистрации глубин, но он равен отношению указанных скоростей, точность определения которых также конечна. В-третьих, даже если предположить отсутствие первых двух факторов ошибок, то всегда имеется и ошибка, заключающаяся в том, что измерения не обязательно будут выполнены в точности от тех же характерных точек дна, что и на стадии промеров. Причина заключается в невозможности идеальной стабилизации скоростей судов, так как всегда будут присутствовать некоторые ускорения, имеющие характер случайных флуктуаций. Как следствие, измеренная в промежуточных точках выборка будет отличаться от идеальной. В принципе, при достаточно подробных промерах влияние такой погрешности не должно быть существенным, так как точки фактических измерений на дне будут близки к используемым на стадии промеров, и вид последовательности глубин не исказится существенным образом.

Можно предположить, что если указанные погрешности не будут иметь характер промахов, приводящих к грубым искажениям последовательностей глубин, то нейронная сеть будет выдавать решение, близкое к наблюдаемому при использовании идеальной выборки глубин. Тем не менее задача определения допустимого уровня погрешностей получения входной последовательности представляется пока нерешенной.

Заключение (Conclusion)

Разработана модель определения местоположения судна по глубинам на основе глубокой нейронной сети прямого распространения с четырьмя скрытыми слоями. Сеть принимает на вход последовательность глубин, измеряемых эхолотом, а на ее выходе получается координата судна на момент последнего измерения глубины. В ходе тестирования показана устойчивость решения к колебаниям уровня моря и постоянным ошибкам измерения глубины, составляющим в сумме ± 5 м. Устойчивость обеспечивается путем случайного видоизменения входных образцов обучающей выборки при сохранении выходных без изменений. В процессе обучения сети контрольная выборка не используется. Лучшее состояние сети в процессе обучения сохраняется в соответствии с критерием наибольшего значения модуля ошибки прогноза. Непосредственная оптимизация коэффициентов нейронной сети осуществляется методом Adamax. Была исследована также зависимость точности работы нейросети от количества нейронов в скрытых слоях. Увеличением данного количества не удалось повысить точность модели. Также была предпринята попытка увеличения точности за счет увеличения объема обучающей выборки и увеличения количества эпох обучения, но заметных успехов добиться также не удалось.

Дальнейшие направления исследований могут проводиться в области разработки модели, работающей для наиболее важного для практики двумерного случая. Для одномерного случая достигнутую точность уже можно считать удовлетворительной. Одной из основных проблем, связанных с переходом к двумерной навигации по глубинам, является существенное увеличение объема учебных данных, так как при этом резко увеличивается количество возможных вариантов движения судна в пределах заданной акватории. Увеличение объема данных, в свою очередь, закономерно приводит к замедлению процесса обучения и повышению требований к вычислительным возможностям компьютерной техники. Двумерный случай не исключает также актуальную и для одномерного случая проблему неоднозначности решения, когда одной и той же последовательности глубин (на практике — нескольким похожим друг на друга) соответствует несколько различных местоположений судна. Повторяемость рельефа как минимум будет негативно сказываться на результатах обучения нейронной сети. Перспективным направлением исследований является также разработка метода определения пригодности рельефа для батиметрической навигации с учетом полученного решения на основе нейронной сети.

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. 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. 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: труды ежегодной НТК. — 2021. — № 1(76). — С. 259–262.

7. 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.

8. 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.

9. Ююкин И. В. Сплайновое синтезирование картографированного эталона информативности поля в задаче корреляционно-экстремальной навигации / И. В. Ююкин // *Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова*. — 2022. — Т. 14. — № 1. — С. 25–39. DOI: 10.21821/2309-5180-2022-14-1-25-39.

10. 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.

11. 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.

12. 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.

13. Norgren P. A multibeam-based SLAM algorithm for iceberg mapping using AUVs / P. Norgren, R. Skjette // *IEEE Access*. — 2018. — Vol. 6. — Pp. 26318–26337. DOI: 10.1109/ACCESS.2018.2830819.

14. 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.

15. 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.

16. 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.

17. 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.

18. Абрамова А. С. Оценка точности общедоступных цифровых моделей рельефа дна океанов на примере участков покрытия многолучевой съемкой Норвежского и Баренцева морей / А. С. Абрамова // *Геодезия и картография*. — 2021. — Т. 82. — № 1. — С. 13–22. DOI: 10.22389/0016-7126-2021-967-1-13-22.

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. 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. Kamenev, A. A., and A. Y. Tonyshv. “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.

7. 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.

8. 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.

9. Yuyukin, Igor V. “Spline synthesis of the charted reference of the field informativity in mission of correlation-extreme navigation.” *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 14.1 (2022): 25–39. DOI: 10.21821/2309-5180-2022-14-1-25-39.

10. Fakhoury, Daniele, Emanuele Fakhoury, and Hendrik Speleers. “ExSplineNet: An interpretable and expressive spline-based neural network.” *Neural Networks* 152 (2022): 332–346. DOI: 10.1016/j.neunet.2022.04.029.
11. 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.
12. 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.
13. 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.
14. 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.
15. 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.
16. 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.
17. 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.
18. Abramova, A.S. “Accuracy assessment of publicly available digital elevation models of the ocean floor, at the polygons of multibeam data coverage in the Norwegian and Barents Seas.” *Geodesy and Cartography* 82.1 (2021): 13–22. DOI: 10.22389/0016-7126-2021-967-1-13-22.

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: gavitder@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: gavitder@mail.ru, deryabinvv@gumrf.ru

Статья поступила в редакцию 20 июня 2023 г.
Received: June 20, 2023.