

## DEPTH-AIDED PREDICTION OF A VESSEL'S LONGITUDE USING A NEURAL NETWORK

**V. V. Deryabin**

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

*A depth-based method for determining vessel longitude using a neural network is proposed. The input of the network is a vector containing depth values measured at a certain spatial interval using an echo sounder. The output of the network is the longitude corresponding to the position of the last sounding. The network has several hidden layers, varying from one to ten layers. The hidden neurons use hyperbolic tangent activation functions, while the single neuron of the output layer employs a linear activation function. Algorithms for training data generation, network training, and testing are defined. Together, they form the basis for creating a neural network-based system for vessel longitude prediction, implemented in the Python programming language. The TensorFlow library is used for working with neural networks. An official electronic navigational chart is chosen as the source of bathymetric data. Based on the extracted sounding layer, a regular grid is formed, where depth values at the grid nodes are calculated using linear interpolation. The procedure for forming training and test data includes pseudorandom variations of sea level, which may result from both real fluctuations and measurement errors. For the test set, the accuracy of the network is acceptable for navigation, and the results depend on the number of hidden layers. The best accuracy, in terms of minimal maximum absolute longitude prediction error, is achieved with the network having the greatest number of hidden layers. It is also noted that it is necessary to test the developed neural network-based system using vessel motion modelling.*

*Keywords: vessel, longitude, depth, neural network, deep learning, autonomous mode, seabed relief, calculation algorithm, electronic chart, navigation.*

**For citation:**

Deryabin, Victor V. "Depth-aided prediction of a vessel's longitude using a neural network." *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 17.4 (2025): 481–492. DOI: 10.21821/2309-5180-2025-17-4-481-492.

**УДК 656.61:004.032.26**

## ОПРЕДЕЛЕНИЕ ДОЛГОТЫ МЕСТА 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 долготы места судна по рельефу дна с использованием нейронной сети, в качестве входного сигнала которой выступает вектор, содержащий значения глубины, измеренные с определенным пространственным шагом при помощи эхолота. Выходом сети служит значение долготы, соответствующее месту последнего измерения глубины. Сеть имеет несколько скрытых слоев, количество которых варьируется от одного до десяти. Скрытые нейроны обладают функциями активации в виде гиперболического тангенса. Единственный нейрон выходного слоя имеет линейную функцию активации. Определены алгоритмы формирования набора учебных данных, настройки и тестирования нейронной сети, формирующие технологию создания нейросетевой системы прогноза долготы места судна по глубинам и реализованные на языке программирования Python. Для работы с нейронными сетями используется библиотека TensorFlow. В качестве источника данных о глубинах выбирается официальная электронная навигационная карта. На основе извлеченного из нее слоя глубин формируется регулярная сетка, значения в узлах которой определяются линейной интерполяцией. Процедура формирования набора учебных и тестовых данных предполагает псевдослучайные изменения уровня моря, которые могут быть вызваны как реальными колебаниями, так и погрешностями измерений. На тестовой выборке сеть пока-*

зывает приемлемую для навигации точность, причем результаты зависят от количества скрытых слоев. Лучшая точность в виде наибольшего значения модуля ошибки прогноза долготы достигается для сети с наибольшим количеством скрытых слоев. Отмечается также необходимость тестирования разработанной нейросетевой системы на основе моделирования движения судна.

*Ключевые слова:* судно, долгота, глубина, нейронная сеть, глубокое обучение, автономный режим, рельеф дна, алгоритм расчета, электронная карта, навигация.

**Для цитирования:**

Дерябин В. В. Определение долготы места судна по глубинам на основе нейронной сети / В. В. Дерябин // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 4. — С. 481–492. DOI: 10.21821/2309-5180-2025-17-4-481-492. — EDN CJWYZX.

### **Введение (Introduction)**

Для решения задач навигации морских судов необходимо знание точных координат их местоположения. В настоящее время координаты и скорость движения подвижных объектов определяются с высокой точностью при помощи глобальных навигационных спутниковых систем (ГНСС). В соответствии с конвенцией СОЛАС на каждом судне независимо от вместимости должен быть установлен приемник ГНСС или радионавигационной системы наземного базирования. Как известно, ГНСС имеют недостаток, который заключается в их неавтономности, т. е. зависимости от внешней информации, которая может быть подвержена воздействиям как непреднамеренного, так и целенаправленного характера. Данный недостаток ГНСС заставляет задуматься над поиском альтернативных решений. На судах торгового флота в качестве альтернативы ГНСС выступают радиолокационные и визуальные методы определения места в прибрежном плавании, а также астронавигационные — в открытом море. Методы определения местоположения по береговым ориентирам зависят, в частности, от состояния видимости. То же относится и к астрономическим методам. В отношении последних ситуация усугубляется тем, что секстан как навигационный инструмент не входит в перечень обязательного оборудования в соответствии с СОЛАС, несмотря на то, что требования государства флага судна иногда предусматривают его наличие.

В качестве альтернативы радионавигационным методам, а также для их контроля могут выступать методы навигации по глубинам, которые используют эталонные данные о рельефе дна, полученные на основе заранее проведенных промеров. Эталонные данные о подводном рельефе содержатся, например, в электронных навигационных картах (ЭНК), которые признаются СОЛАС в качестве официального источника информации при их использовании в электронных картографических навигационных информационных системах (ЭКНИС). В качестве инструмента измерений в режиме навигации может выступать однолучевой эхолот, который является обязательным для всех судов валовой вместимостью 300 и более. Таким образом, навигация судна по глубинам может быть организована в рамках стандартного укомплектования навигационным оборудованием многих морских судов. Подобного рода решения рассматриваются, например, в монографии [1]. Вопросам корреляционно-экстремальной навигации посвящены работы [2] и [3].

Использование поля рельефа для навигации подвижных объектов известно давно. Так, например, в [4] был опубликован алгоритм, который получил название TERCOM (Terrain Contour Matching). Его идея заключается в сравнении измеренной вдоль определенного направления текущей последовательности высоты рельефа с эталонными данными, в результате чего определяется наиболее близкое совпадение и становится возможным определение координат, так как все эталонные последовательности имеют привязку к местности. В принципе, идея данного метода уже используется в патенте [5]. На основе предварительных промеров создаются профили глубин, каждый из которых соответствует определенному направлению движения в районе плавания. Измеряется текущий профиль, и на основе данных счисления при помощи механической линейки с транспортиром выполняется поиск наиболее близкого эталонного профиля, с которым соотносятся координаты судна. Такого рода TERCOM-подобные методы относятся к классу поисковых. Работают они обычно совместно с системой счисления, которая позволяет не только

сократить область поиска до границ области неопределенности координат, но также и обеспечить измерение глубины в заданные моменты времени в заданном направлении движения.

Существенным ограничением поисковых методов навигации по эталонным данным является то, что при большой области поиска могут возникнуть проблемы с обеспечением быстродействия вычислений в режиме реального времени. Действительно, площадь области неопределенности счисления постоянно увеличивается, и процесс поиска занимает все большее время до тех пор, пока не будет получено надежное местоположение, выбранное в качестве новой начальной точки для счисления. Проблемы с обеспечением быстродействия заставляют задуматься над поиском новых решений, которые могут быть менее чувствительны к ограничениям по мощности вычислительных ресурсов. В качестве подобных решений целесообразно использовать искусственные *нейронные сети*, так как, во-первых, они позволяют организовать быстрые вычисления на специальных нейропроцессорах и, во-вторых, они известны в качестве инструментов универсальной аппроксимации функций многих переменных, а такая постановка задачи, в принципе, и наблюдается в рамках TERCOM-подхода. Таким образом, основная идея заключается в том, что сеть заранее обучается на большом объеме эталонных данных о глубинах на заданной акватории, в результате чего в ее коэффициентах содержится информация о соотношении глубин и координат. В режиме навигации на вход сети подается последовательность глубин, а на выходе получаются координаты. Иными словами, вместо полной эталонной базы данных о рельефе используется набор весов и пороговых значений сети, который значительно меньше по объему и главное не предполагает поиск в реальном времени.

Указанные идеи использования нейронных сетей были реализованы в исследованиях [6]–[8] (рассмотрены одномерный и двумерный случаи). В [9] предлагается отдельный подход к прогнозированию координат и рассмотрена сеть, прогнозирующая широту места судна по глубинам. В настоящей статье рассматривается прогнозирование долготы судна нейросетью на основе данных о глубинах.

### Методы и материалы (Methods and Materials)

**Постановка задачи.** Будем считать, что с использованием однолучевого эхолота вдоль некоторого направления  $K$  измеряются с пространственным шагом  $\Delta s$  значения глубины  $d$ , которые образуют последовательность  $d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1}$ , в которой  $p$  представляет собой количество значений глубин, используемых для прогноза долготы судна  $\lambda$ . Величина  $k$  может принимать значения от 0 до  $n - p + 1$ , где  $n + 1$  — общее количество значений глубин в наборе эталонных данных. Соответствующая последовательность значений долготы имеет вид:  $\lambda_k, \lambda_{k+1}, \lambda_{k+2}, \dots, \lambda_{k+p-1}$ . Необходимо на основе нейронной сети выполнить преобразование  $f$  следующим образом:

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

Иными словами, возникает задача регрессии или приближения функции нескольких переменных  $f(\cdot)$ , с которой нейронные сети, как известно (см., например, [10] и [11]), успешно справляются при условии корректного выбора их архитектуры, алгоритмов формирования набора учебных данных, обучения и тестирования.

Следует отметить, что похожая постановка задачи приводится в исследовании [9]. Отличие заключается в том, что в соотношении (1) в качестве зависимой переменной вместо долготы используется широта судна.

**Архитектура нейронной сети.** Среди большого разнообразия возможных вариантов архитектур нейронных сетей будем использовать сети прямого распространения, которые содержат несколько скрытых слоев. При этом под скрытым слоем будем понимать слой, который не имеет соединения с выходными сигналами. Первый скрытый слой принимает данные от слоя входных сигналов. Также будем считать, что сигнальные связи между слоями полные, т. е. любой нейрон текущего слоя соединяется с каждым нейроном последующего слоя. Причем направление движения сигнала возможно только от входа к выходу (прямое распространение сигнала). В соответствии

с требованиями универсальной аппроксимации нейроны скрытых слоев обладают нелинейными функциями активации (в данном конкретном случае в виде гиперболического тангенса), а нейрон выходного слоя — тождественной функцией, т. е. он оставляет взвешенную сумму поступающих на его вход сигналов без изменений.

*Формирование образцов.* Набор учебных данных включает образцы, т. е. пары «вход-выход», определенные в соответствии с соотношением (1). В качестве входного сигнала сети выступает последовательность глубин  $d_k, d_{k+1}, d_{k+2}, \dots, d_{k+p-1}$ , а в качестве выходного  $\lambda_{k+p-1}$  — значение долготы на момент измерения последней глубины  $d_{k+p-1}$ . В соответствии с постановкой задачи измерения глубины в режиме навигации должны выполняться в узлах регулярной сетки, поэтому образцы также должны соответствовать измерениям на регулярной сетке. Вопрос ее формирования рассмотрим более подробно.

В качестве источника информации о глубинах используется электронная навигационная карта US4SC31M, точнее, ее слой глубин SOUNDG. Район плавания, для которого создается система навигации по глубинам, ограничен параллелью с широтой  $32^\circ 52,5' N$  с Юга, меридианом с долготой  $079^\circ 05,8' W$  с Запада, параллелью с широтой  $33^\circ 12,6' N$  с Севера, меридианом с долготой  $078^\circ 41,9' W$  с Востока. Размеры акватории составляют приблизительно  $20 \times 20$  миль. Далее в пределах указанного района плавания формируется регулярная сетка меридианов и параллелей с фиксированным шагом по широте и долготе. Предполагая, что рекомендуемое направление движения  $K = 0$ , т. е. с юга на север и количество глубин для прогноза долготы равно  $p$ , сформируем эталонную матрицу глубин  $D$ :

$$D = \begin{pmatrix} d_0 & d_1 & \dots & d_{p-1} \\ d_1 & d_2 & \dots & d_p \\ \dots & \dots & \dots & \dots \\ d_{n-p+1} & d_{n-p+2} & \dots & d_n \end{pmatrix}.$$

Каждая строка матрицы  $D$  соответствует конкретному значению входного сигнала нейронной сети. Поскольку глубины на карте представлены, как правило, не в точности в узловых точках формируемой сетки, используются методы интерполяции (часто линейной) для определения необходимых значений.

Аналогичная матрица может быть составлена и для долготы:

$$\Lambda = \begin{pmatrix} \lambda_0 & \lambda_1 & \dots & \lambda_{p-1} \\ \lambda_1 & \lambda_2 & \dots & \lambda_p \\ \dots & \dots & \dots & \dots \\ \lambda_{n-p+1} & \lambda_{n-p+2} & \dots & \lambda_n \end{pmatrix}.$$

Значению выходного сигнала соответствует последний элемент каждой строки матрицы  $\Lambda$ , номер которой равен индексу соответствующей строки матрицы  $D$ . Задача определения координат на основе TERCOM сводится к поиску в матрице  $D$  такой строки, которая будет наиболее близка к последовательности глубин, полученных в результате текущих измерений. В качестве степени близости может быть выбран, например, средний или максимальный модуль разности между текущей строкой и эталонной. При этом предполагается, что критерий близости вычисляется для тех строк матрицы  $D$ , которые соответствуют области неопределенности координаты, что может быть определено уже на основе эталонной матрицы  $\Lambda$ . В ней нужно найти такие строки, все элементы которых (значения долготы) принадлежат области неопределенности системы счисления пути судна. Далее необходимо рассматривать только те строки матрицы  $D$ , которые соответствуют оставшимся строкам  $\Lambda$ . Следует отметить, что процедура поиска строк  $\Lambda$ , находящихся в области неопределенности, также требует вычислительных ресурсов и имеет смысл, только если она выполняется быстрее, чем полный поиск с использованием всех строк эталонных матриц.

В рамках нейросетевого подхода на основе эталонных матриц  $D$ ,  $\Lambda$  формируются образцы, представляющие собой пары «вход-выход». В задачах машинного обучения часто приходится иметь дело с выборками трех типов: обучающей, контрольной и тестовой. *Обучающая выборка* содержит эталонные данные, которые непосредственно используются для настройки нейронной сети, т. е. на основе которых решается задача оптимизации свободных параметров (весовых коэффициентов и пороговых значений). *Контрольная выборка* используется для контроля обобщающих свойств сети, чтобы не допустить ее переобучения, когда сеть начинает просто запоминать конкретный набор данных, теряя при этом способность к обобщению, что выражается в потере робастности на этапе тестирования. Качество работы нейронной сети для образцов как контрольной, так и обучающей выборок характеризуется определенным критерием, в качестве которого часто используется средний квадрат ошибки. Выбор данного критерия для обучающей выборки удобен тем, что для него легко вычисляются производные, что актуально для алгоритма обратного распространения ошибки. Для контрольной выборки критерий может быть задан произвольно исходя из специфики решаемой задачи. В данном случае используется наибольшее значение модуля ошибки прогноза долготы. Несколько обособленно находится *тестовая выборка*. Она не используется непосредственно в процессе обучения, но позволяет судить о степени работоспособности нейронной сети после завершения обучения. Критерии качества работы могут быть различными. В данном случае используются наибольшее и среднее значения модуля ошибки прогноза долготы.

При формировании выборок возникают вопросы, связанные с количеством и качеством составляющих их образцов. Обучающая выборка должна быть репрезентативной, т. е. содержать достаточное количество образцов, характеризующих работу сети в определенной области пространства входного сигнала. При этом слишком большое количество образцов, среди которых много похожих друг на друга, «повторяющихся», будет затруднять процесс обучения, увеличивая время настройки сети. Указанное справедливо также и для контрольной выборки, но при этом хотелось бы, чтобы ее образцы находились как бы между образцами обучающей выборки, не совпадали с ними, но имели заметные отличия от них. Требования к формированию тестовой выборки совпадают с требованиями для контрольной с тем отличием, что для тестовой количество образцов должно быть таким, чтобы охватить как можно больше возможных значений входного сигнала сети. Для контрольной выборки слишком большое количество данных может существенно замедлить процесс настройки нейронной сети, поскольку они используются непосредственно для расчета показателя точности на итерациях обучения, т. е. многократно.

Рассмотрим процесс формирования выборок трех перечисленных типов более подробно. Основу обучающей выборки образуют эталонные матрицы  $D$ ,  $\Lambda$ . При этом матрица  $D$  подвергается псевдослучайным вариациям: к каждому ее элементу прибавляется псевдослучайная величина  $\delta$ , которая представляет собой изменение уровня моря на акватории, в пределах которой осуществляется навигация по рельефу дна. Существование величины  $\delta$  объясняется приливо-отливными явлениями, сгонно-нагонными процессами ветровой природы, а также систематическими ошибками эхолота. Конкретное значение суммы  $D + \delta$  может рассматриваться как некий псевдослучайный вариант (реализация) матрицы  $D$ . При этом эталонная матрица долготы  $\Lambda$  таким вариациям не подвергается, т. е. ее элементы остаются неизменными. Получается, что одной и той же координате соответствует уже не одна строка из матрицы  $D$ , а  $r_1 + 1$  строк, где  $r_1$  — количество псевдослучайных вариаций матрицы  $D$ . Таким образом, обучающая выборка формируется на основе  $r_1 + 1$  пар  $\{D + \delta, \Lambda\}$ , для одной из которых  $\delta = 0$ . Подобные вариации направлены не только на увеличение количества образцов, но и на повышение уровня робастности нейронной сети, которая должна обеспечиваться в реальных условиях эксплуатации, предполагающих, что в точности строки из матрицы  $D$  в общем случае не будут подаваться на вход сети и придется иметь дело с их искаженными версиями. Аналогичным образом формируются образцы для контрольной и тестовой выборок с тем лишь отличием, что сама матрица  $D$  не используется, а используются только ее псевдослучайные реализации. Количество таких реализаций для контрольной

выборки обозначим через  $r_2$ , а для тестовой — через  $r_3$ . Таким образом, если, например,  $r_1 = r_2 = r_3$ , то при прочих равных условиях образцов в обучающей выборке должно быть больше, чем в контрольной и тестовой.

При формировании набора учебных данных следует учитывать также следующее обстоятельство. Может так получиться, что значение какого-либо элемента видоизмененной матрицы  $D$ , т. е.  $D + \delta$  примет значение, которое не имеет смысла использовать для целей навигации по глубинам. Например, одна из глубин составляет 2 м, но с учетом  $-3 \text{ м} \leq \delta \leq 3 \text{ м}$  ее значение после изменения может составлять, например,  $-0,5 \text{ м}$  (при  $\delta = -2,5 \text{ м}$ ). Понятно, что «отрицательная» глубина не может использоваться. В связи с ранее изложенным целесообразно также ввести в рассмотрение минимальное допустимое значение глубины  $d_{\min}$ , которое можно использовать в навигационных целях. Указанное значение может быть определено, например, на основе минимально допустимого значения глубины под килем для судов, которые планируют использовать систему навигации по глубинам. Если хотя бы один элемент какой-либо строки  $D + \delta$  окажется менее  $d_{\min}$ , то соответствующий ей образец не формируется и не включается в выборку. Следует отметить, что использование  $d_{\min}$  в качестве дополнительного параметра алгоритма формирования образцов актуально в районах с малыми глубинами. Например, в рассматриваемом случае для карты US4SC31M в пределах района навигации наименьшее значение глубины составляет 6,7 м при максимальном значении, равном 32,8 м.

После получения набора учебных данных образцы часто подвергают процедуре масштабирования. Смысл ее заключается в том, что задаются границы интервала масштабирования  $[\min, \max]$ , в которые приводятся значения исходной величины, где наибольшему значению соответствует  $\max$ , а наименьшему —  $\min$ . Промежуточные значения определяются линейной интерполяцией (точная формула содержится, например, в [9]). В итоге алгоритм обучения использует уже масштабированный вариант обучающей выборки. Следует отметить, что на этапе тестирования и использования нейросетевой системы к ее выходу необходимо выполнять обратное по отношению к указанному масштабированию преобразование. При этом входные образцы масштабируются так же, как это выполняется на этапе формирования образцов.

Процедура масштабирования помимо величин  $\min$ ,  $\max$  также предполагает использование наименьшего и наибольшего значений глубины, которые могут наблюдаться для рассматриваемого района плавания. Наименьшее значение глубины (для масштабирования) выбирается равным или  $d_{\min}$  или минимальному значению глубины минус величина  $A_\delta$  (наибольший возможный модуль изменения уровня моря  $\delta$ ). Последний вариант выбирается, когда разность более  $d_{\min}$ , в противном случае выбирается  $d_{\min}$ . Наибольшее значение глубины (для масштабирования) всегда выбирается как максимальное значение глубины плюс величина  $A_\delta$ . Если в режиме навигации наблюдается выход текущего значения глубины за пределы масштабирования, то необходимо брать сами пределы в качестве текущих значений. Выход за правую границу может наблюдаться, если текущий уровень моря отличается (в большую сторону) от эталонного более чем на  $A_\delta$ . Выход за левую границу предельных значений происходит по аналогичным причинам с той особенностью, что предельно низкий уровень должен быть ограничен  $d_{\min}$  даже в том случае, когда не  $d_{\min}$  принято в качестве левой границы.

Матрица  $D$  сформирована для направления движения с юга на север. Очевидно, что ее можно использовать и для обратного направления, т. е. с севера на юг. Для этого достаточно просто поменять порядок следования элементов строк на обратный в матрицах  $D$ ,  $\Lambda$  и далее следовать тому же алгоритму формирования образцов, что и для исходного направления. Понятно также и то, что матрицу  $D$  можно использовать и для рекомендуемых направлений с запада на восток и обратно. Для реализации указанного необходимо использовать, в частности, операцию транспонирования матрицы. Для промежуточных направлений вопрос использования матрицы  $D$  подлежит дополнительному исследованию. Дело, в частности, заключается в том, что в случае главных румбов движение происходит вдоль либо меридианов, либо параллелей, а для промежуточного направления — вдоль локсодромий. При том же самом пространственном

разрешении координаты узловых точек меняются. Их определение требует дополнительных вычислений на основе информации, не содержащейся непосредственно в матрице  $D$ .

Таким образом, параметрами алгоритма формирования набора учебных (и тестовых) данных являются:

- рекомендуемое направление движения  $K$ ;
- шаг по широте и долготе;
- количество значений глубин  $p$ , используемых для прогноза долготы;
- предельная ошибка уровня моря  $A_\delta$  ( $-A_\delta \leq \delta \leq A_\delta$ );
- количество псевдослучайных вариаций  $r_1, r_2$  (и  $r_3$  для тестовой выборки);
- наименьшее допустимое значение глубины  $d_{\min}$ ;
- границы интервала масштабирования образцов  $\min, \max$ .

*Обучение нейронной сети.* Для обучения (настройки) нейронной сети будем применять алгоритм Adamax [12], относящийся к классу градиентных методов оптимизации первого порядка. Один шаг данного алгоритма применяется на каждой итерации цикла, на которой отслеживается показатель точности в виде наибольшего значения модуля ошибки прогноза долготы, рассчитанного для образцов из контрольной выборки. Наиболее оптимальное состояние сети сохраняется в соответствии именно с данным критерием. При этом оптимизационная процедура выполняется для традиционного среднего квадрата ошибки, вычисленного для образцов из обучающей выборки. Сам по себе алгоритм Adamax имеет несколько параметров, которые могут быть изменены. Их описание содержится, например, в документации TensorFlow вер. 2.16.1. Также в рамках библиотеки TensorFlow предусмотрена возможность использования алгоритма регуляризации в целях предотвращения переобучения нейронной сети.

Как известно, процедура регуляризации не позволяет отдельным весовым коэффициентам принимать слишком большие значения, что может являться косвенным признаком переобучения. Для этого переходят к целевой функции, которая содержит не просто средний квадрат ошибки, а также слагаемое, которое учитывает значения весовых коэффициентов сети, подлежащих настройке. Учет величин коэффициентов может быть реализован, например, в виде суммы их модулей или суммы их квадратов. Возможны также и комбинации данных вариантов.

Обучение нейронных сетей происходит в общем случае в мини-пакетном режиме. Когда в мини-пакете всего один образец, то речь идет о последовательном режиме обучения (коррекция весов выполняется после рассмотрения каждого образца из обучающей выборки). Когда в мини-пакете содержатся все образцы из обучающей выборки, сеть обучается в пакетном режиме (коррекция весов выполняется после рассмотрения сразу всех образцов из обучающей выборки). Таким образом, последовательный режим обучения и пакетный режим являются частными случаями мини-пакетного режима. В любом случае размер мини-пакета также является параметром процедуры обучения нейросети.

Еще один параметр процедуры настройки связан с остановкой процесса обучения нейросети. Часто в роли данного критерия выбирается максимальное количество итераций (эпох), по прошествии которого алгоритм обучения завершается. В качестве альтернативы может быть выбрано также наибольшее время работы алгоритма, что предполагает зависимость от вычислительных возможностей компьютера, на котором выполняется обучение. Не исключен случай, когда процесс останавливается по достижении нейронной сетью необходимой точности.

*Проверка работоспособности нейронной сети.* Для проверки работоспособности нейросети используется тестовая выборка, которая формируется точно по такому же принципу, что и контрольная с использованием  $r_3$  псевдослучайных вариаций эталонной матрицы глубин  $D$ . Следует отметить, что с понятием работоспособности связано понятие робастности, т. е. устойчивости нейронной сети к изменениям входных данных по отношению к тем, которые наблюдались на этапе обучения. Критерием робастности при этом служит обычно та же величина, что использовалась для расчета точности на этапе обучения для образцов из контрольной выборки. Следует также отметить, что предлагаемый метод тестирования учитывает только колебания уровня моря (реальные

или из-за ошибок измерений), в чем и заключается его ограничение, так как в действительности искажения входного сигнала могут наблюдаться также ввиду ограниченной точности счисления на этапе использования нейронной сети (в режиме навигации).

### Результаты (Results)

Рассмотренные ранее основные этапы создания нейросетевой системы навигации по глубинам были выполнены с использованием языка программирования Python. В качестве библиотеки обучения нейронных сетей выбрана TensorFlow вер. 2.16.1 (Keras). Нейронная сеть имеет один скрытый слой, содержащий 200 нейронов с функцией активации в виде гиперболического тангенса.

Параметры алгоритма формирования набора учебных и тестовых данных принимают следующие значения:

- рекомендуемое направление движения  $K = 0$ ;
- шаг по широте и долготе — 0,5 мили;
- количество значений глубин, используемых для прогноза долготы:  $p = 20 + 1$ ;
- предельная ошибка уровня моря  $A_{\delta} = 1$  м;
- количество псевдослучайных вариаций  $r_1 = r_2 = 100$ ,  $r_3 = 1000$ ;
- наименьшее допустимое значение глубины  $d_{\min} = 1$  м;
- границы интервала масштабирования образцов  $\min = -1$ ,  $\max = +1$ .

Процесс обучения был запущен с максимальным количеством итераций, равным 5000. Каждый мини-пакет содержит 100 образцов. По прошествии всех 5000 эпох наименьшее значение максимального модуля ошибки прогноза долготы (для контрольной выборки) было зафиксировано на 4805-й итерации и составило  $0,032218^{\circ}$ . Для данного района плавания такая ошибка соответствует примерно 3015 м на эллипсоиде WGS-84. Кривая обучения изображена на рисунке.




График процесса обучения  
(контрольная выборка, один скрытый слой)

Вычислив наибольший и средний модули ошибки обученной нейронной сети для тестовой выборки, получим следующие значения:  $0,03424^{\circ}$  и  $0,004154^{\circ}$ . Для рассматриваемого района плавания указанные показатели соответствуют примерно 3204 и 389 м, что вряд ли можно считать хорошим результатом с точки зрения навигационного использования.

Рассмотрим другие варианты архитектуры нейронной сети, отличающиеся от рассмотренной количеством скрытых слоев (глубокие архитектуры). Результаты сведем в следующую таблицу.

### Результаты обучения и тестирования нейронной сети

| Количество скрытых слоев | Обучение                             |                                       | Тестирование                |                            |
|--------------------------|--------------------------------------|---------------------------------------|-----------------------------|----------------------------|
|                          | Наименьший максимум модуля ошибки, ° | Номер итерации минимального максимума | Наибольший модуль ошибки, ° | Средний модуль ошибки, °   |
| 1                        | 0,032218                             | 4805                                  | 0,03424                     | 0,004154                   |
| 2                        | 0,001975                             | 4721                                  | 0,002451                    | 0,000248                   |
| 3                        | 0,000852                             | 3240                                  | 0,002978                    | 0,000226                   |
| 4                        | 0,000761                             | 1087                                  | 0,003115                    | <b>9,9·10<sup>-5</sup></b> |
| 5                        | 0,000651                             | 4928                                  | 0,002643                    | 0,000127                   |
| 10                       | 2,1·10 <sup>-5</sup>                 | 3441                                  | <b>0,000495</b>             | 0,00015                    |

В столбце «Обучение» приведено наименьшее значение максимума модуля ошибки прогноза долготы (для контрольной выборки) и номер той эпохи, для которой это наименьшее значение достигается. В столбце «Тестирование» приводятся характеристики точности сетей, которые они обнаруживают на этапе тестирования, т. е. рассчитанные для образцов тестовой выборки. Лучшие результаты тестирования выделены жирным шрифтом.

### Обсуждение (Discussion)

Как следует из данных таблицы, лучший результат (в смысле максимума модуля ошибки прогноза долготы) был получен для нейронной сети, содержащей 10 скрытых слоев. Указанный критерий составил 0,000495°, что соответствует примерно 46,3 м на поверхности общеземного эллипсоида WGS-84. При этом средняя точность составляет 14 м. В принципе, такую точность можно считать вполне приемлемой для навигационных целей. Увеличение числа скрытых слоев в целом позволило увеличить точность прогноза долготы нейронной сетью. Интересно также отметить, что наилучшее значение среднего модуля ошибки на тестовой выборке зафиксировано для сети, имеющей четыре скрытых слоя, а не той, которая оптимальна в смысле наибольшего модуля ошибки прогноза.

Если рассматривать критерий точности, рассчитанный для образцов из контрольной выборки (см. таблицу), то наблюдается его уменьшение по мере увеличения количества скрытых слоев нейронной сети, т. е. точность тем лучше, чем больше количество скрытых слоев сети, т. е. чем сеть глубже. Для критериев точности, рассчитанных для тестовой выборки, такое правило строго не соблюдается, хотя определенная тенденция на увеличение точности в связи с увеличением количества скрытых слоев наблюдается. Отдельного внимания заслуживает мелкая нейронная сеть (с одним скрытым слоем), все характеристики точности которой принимают наибольшие (наихудшие) значения. Таким образом, если сеть с большим количеством слоев прогнозирует более точно долготу для образцов контрольной выборки, то это не обязательно означает, что сеть с меньшим количеством слоев будет менее точной для образцов из тестовой выборки. Возможно, при большем количестве тестовых данных соотношение архитектур сетей и критериев точности будет несколько иным, но для текущих тестовых выборок результаты получились такими.

Номер итерации, на которой был зафиксирован наилучший показатель точности для контрольной выборки, для сетей с одним, двумя, тремя и четырьмя скрытыми слоями закономерно уменьшается по мере увеличения количества скрытых слоев. Так, например, для однослойной сети лучший результат был зафиксирован на 4805-й итерации, а для четырехслойной — на 1087-й. Действительно, чем больше свободных параметров имеет сеть, тем переобучение, казалось бы, должно, как правило, начинаться раньше, так как размер обучающей выборки остается неизменным. Однако неожиданный результат был получен по мере увеличения количества скрытых слоев сначала до пяти, а затем и до десяти. Номер оптимальной итерации увеличился (для пяти слоев), а затем вновь уменьшился (для десяти слоев), но оказался существенно большим, чем для сети с четырьмя скрытыми слоями. Возможно, данный факт можно объяснить тем,

что на переобучение влияет не только соотношение между свободными параметрами сети и объемом обучающей выборки, но также и алгоритм инициализации весовых коэффициентов сети, который, в свою очередь, влияет на сходимость алгоритма обучения и содержит определенный элемент случайности.

Следует обратить также внимание на график процесса обучения, приведенный на с. 488. В своей общей тенденции кривая обучения описывает убывающую функцию. Однако скорость такого убывания различна на разных участках. Можно выделить по меньшей мере три участка, отличающихся скоростью убывания критерия точности. Первый участок (приблизительно от 0 до 300 итераций) характеризуется стремительным падением наибольшего модуля ошибки прогноза долготы. На втором участке (приблизительно от 500 до 1800) уменьшение указанного критерия уже не такое быстрое, как на первом. На третьем участке (приблизительно от 2000 и до конца обучения) наблюдается самая слабая тенденция к уменьшению целевого показателя. Кривая обучения здесь как бы асимптотически приближается к некоторому минимально возможному значению, что косвенно может указывать на то, что существенно увеличить точность за счет дальнейшего увеличения максимального количества итераций быстро вряд ли получится. Другой особенностью кривой обучения является ее шумовой характер. Конечно, такие шумовые колебания не слишком существенны на фоне общей тенденции критерия к уменьшению, но тем не менее они наблюдаемы, что подтверждает правильность применяемого подхода к обучению, когда интересующий целевой критерий определяется на каждой итерации, и лучшее состояние сети в соответствии с ним сохраняется в качестве наиболее оптимального. Шумовой характер сам по себе в рассматриваемом случае не позволяет однозначно судить о наличии неустойчивости процесса обучения, поскольку алгоритм обучения минимизирует средний квадрат ошибки, а не максимальный ее модуль.

Ответ на вопрос: *чем отличается обученная нейронная сеть от традиционного TERCOM-алгоритма*, может быть следующим. Оба алгоритма используют эталонные данные, TERCOM использует указанные данные непосредственно в режиме навигации. Каждый раз по мере поступления новых измерений выполняется поиск по базе эталонных данных (матрице  $D$ ). Нейронная сеть использует эталонные данные только на этапе обучения, которое может быть выполнено с использованием мощных компьютеров на берегу заранее. Далее вся информация хранится в наборе весовых коэффициентов сети, объем которого, как правило, намного меньше, чем объем учебных данных в виде эталонных матриц, и в режиме навигации он непосредственно не нужен, так как вся информация уже имеется в виде коэффициентов. Конечно, критическое значение для нейросетевого подхода имеет степень робастности сети, работающей с реальными выборками глубин.

### Заключение (Conclusion)

В ходе выполнения настоящего исследования были последовательно решены следующие задачи: выбрана архитектура нейронной сети, прогнозирующей долготу судна по глубинам; сформирован набор учебных данных для ее настройки; проведено обучение, а также определен способ тестирования уже обученной сети. Результаты тестирования показали, что нейронная сеть позволяет прогнозировать долготу места судна с хорошей точностью. Было рассмотрено несколько архитектур, отличающихся количеством скрытых слоев, что позволило выявить их влияние на точность, критерии которой определялись для образцов из тестовой выборки. В частности, лучший результат по критерию максимума модуля ошибки прогноза был получен для самой глубокой нейросетевой архитектуры, содержащей десять скрытых слоев. Использование такой сети в комбинации с сетью, прогнозирующей широту, представляет собой использование нейросетевого алгоритма определения координат места судна по глубинам. Тем не менее к полученным результатам тестирования необходимо относиться как к предварительным. Дело в том, что искажение входного сигнала, в качестве которого выступает последовательность глубин, измеренных эхолотом через равные отрезки пройденного судном расстояния, может быть вызвано не только колебаниями уровня моря. Искажение может происходить также по причине конечной точности

счисления, которое используется, во-первых, для обеспечения движения судна вдоль рекомендованного направления в области батиметрической навигации и, во-вторых, для определения приращений пройденного расстояния для выполнения промеров.

Поэтому важным развитием настоящего исследования является применение такого метода тестирования, который может учитывать ограничения точности счисления, характерные для конкретного судна в заданном районе плавания. Подобный метод может быть реализован на основе моделирования движения судна. Последнее, в свою очередь, может быть выполнено как с использованием уравнений динамики судна, так и с использованием только кинематических соотношений для описания его движения на поверхности Земли. Такой подход позволит, в принципе, предварительно оценить робастность сети в условиях, в определенной степени приближенных к реальной навигации. Конечно, окончательное тестирование должно проводиться в реальных условиях плавания. Другим важным направлением исследований является определение такой архитектуры нейронной сети, которая была бы оптимальной не только с точки зрения точности, но также и быстродействия, обеспечение которого тоже имеет значение, так как нейросетевой алгоритм предполагается к применению в режиме реального времени.

### СПИСОК ЛИТЕРАТУРЫ

1. Ключева С. Ф. Синтез алгоритмов батиметрических систем навигации / С. Ф. Ключева, В. В. Завьялов. — Владивосток: Морской 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. Патент 3212189, США. Marine navigation procedure / Savit C. H.; опуб. 19.10.1965.
6. 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. — 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 имени 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 имени 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. 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.
10. Wang M–X. Approximation capabilities of neural networks on unbounded domains / M–X. Wang, Y. Qu // Neural Networks. — 2022. — Vol. 145. — Pp. 56–67. DOI: 10.1016/j.neunet.2021.10.001.
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. Kingma, J. Ba // 3rd International Conference on Learning Representations. — 2015. DOI: 10.48550/arXiv.1412.6980.

### REFERENCES

1. Klyueva, S. F. and V. V. Zav'yalov. *Sintez algoritmov batimetricheskikh sistem navigatsii* Vladivostok: Mor. gos. un-t, 2013: 132.

2. Stepanov, O. A. *Metody otsenki potentsial'noy tochnosti v korrelyatsionno-ekstremal'nykh navigatsionnykh sistemakh Analiticheskiy obzor* SPb: TsNII "Elektropribor", 1993: 84.
3. Ma, D., Y. Ben, et al. "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. Savit, Carl H. Patent No. 3,212,189. Marine navigation procedure. U. S. Publ. 19 Oct. 1965.
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, Victor V., Sazonov Anatoly E. "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.
10. Wang, M–X. and Y. Qu. "Approximation capabilities of neural networks on unbounded domains." *Neural Networks* 145 (2022): 56–67. DOI: 10.1016/j.neunet.2021.10.001.
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 Ba Jimmy. "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 06 июня 2025 г.  
Received: June 06, 2025.