

Научная статья

УДК 629.12

<https://doi.org/10.24866/2227-6858/2025-3/55-68>

Прогнозирование главных размерений судна на стадии предварительного проектирования с использованием искусственной нейронной сети

Герман Китио✉, Вероника Ростиславовна Душко, Даниил Юрьевич Несин

Севастопольский государственный университет,

Севастополь, Российская Федерация

✉ hermannkitio94@gmail.com

Аннотация. В настоящей работе изучалось применение искусственных нейронных сетей (ИНС) в проектировании судов. В отличие от эмпирических формул и статистических методов, ИНС предлагают гибкую и эффективную альтернативу, продемонстрировав свою способность точно моделировать сложные системы. Цель данного исследования – разработать модель ИНС для прогнозирования главных размерений рыболовных судов на стадии предварительного проектирования. Входной слой включал водоизмещение и скорость судна, а выходной слой – главные размерения корпуса (наибольшая длина, ширина, осадка и высота борта). Используя данные о 590 рыболовных судах, исключая сестринские суда, разработанная модель ИНС показала многообещающие результаты с минимальными погрешностями. Метрики, такие как средняя абсолютная процентная ошибка (MAPE) и коэффициенты корреляции, подчёркивают адекватность модели и высокую предсказательную точность измеряемых размерений (длины L, ширины B, высоты H и осадки T).

Ключевые слова: искусственные нейронные сети, средняя абсолютная процентная ошибка, предварительное проектирование, входной слой, выходной слой

Для цитирования: Китио Г., Душко В.Р., Несин Д.Ю. Прогнозирование главных размерений судна на стадии предварительного проектирования с использованием искусственной нейронной сети // Вестник Инженерной школы Дальневосточного федерального университета. 2025. № 3(64). С. 55–68.

DESIGN AND CONSTRUCTION OF SHIPS

Original article

Prediction of a ship's principal dimensions at the preliminary design stage using an artificial neural network

Hermann Kitio✉, Veronika R. Dushko, Daniil Yu. Nesin

Sevastopol State University, Sevastopol, Russian Federation

✉ hermannkitio94@gmail.com

Abstract. This study investigates the application of artificial neural networks (ANNs) in ship design. Unlike empirical formulas and statistical methods, ANNs provide a flexible and efficient alternative, demonstrating their ability to accurately model complex systems. The objective of this research is to develop an ANN model for predicting the principal dimensions of fishing vessels at the preliminary design stage. The input layer included the vessel's displacement and service speed, while the output layer comprised the main hull dimensions—length overall, breadth, draft, and depth. Using a dataset of 590 fishing vessels, excluding sister ships, the developed ANN model demonstrated promising results with minimal errors. Performance metrics such as the Mean Absolute Percentage Error (MAPE) and correlation coefficients highlight the adequacy of the model and its high predictive accuracy for the principal dimensions (length L, breadth B, draft T, and depth D).

Keywords: artificial neural networks, mean absolute percentage error, preliminary design, input layer, output layer

For citation: Kitio H., Dushko V.R., Nesin D.Yu. Prediction of a ship's principal dimensions at the preliminary design stage using an artificial neural network. *FEFU: School of Engineering Bulletin*, 2025, no. 3(64), pp. 55–68. (In Russ.).

Введение

Проектировщики морских судов придерживаются чётко регламентированного процесса, включающего три этапа: предварительное проектирование, контрактное проектирование и детальное проектирование. Этот итеративный подход, иллюстрируемый Дж. Х. Эвансом [1] в 1959 году в виде спирали проектирования, начинается с определения основных спецификаций судна на этапах концептуального и предварительного проектирования. Традиционно для определения этих спецификаций используются статистические уравнения регрессии, однако устаревшие эмпирические формулы не всегда отвечают современным требованиям, таким как увеличивающееся отношение DWT/L. Актуализация таких формул необходима, но её проведение сопряжено со значительными экспериментальными издержками и часто даёт результаты с недостаточной надёжностью.

В отличие от этого, нейронные сети предлагают многообещающую альтернативу статистическим методам. Они обеспечивают большую гибкость и могут быстро создавать точные модели сложных систем, что демонстрирует их потенциал для улучшения точности и эффективности процессов проектирования судов [2].

В последние годы искусственные нейронные сети (ИНС) находят всё более широкое применение в различных областях инженерии. Тем не менее их использование в задачах проектирования и оценки остаточной остойчивости судов остаётся относительно редким. Clausen и соавт. [3] разработали модель ИНС для определения главных размерений контейнеровозов на этапе предварительного проектирования и провели её сравнение с результатами, полученными с помощью регрессионного анализа и байесовских сетей. Полученные данные показали, что ИНС обеспечивают более высокую точность по сравнению с другими методами, при этом средняя ошибка колебалась в пределах от 4 до 9%. Alkan и др. [4] разработали две ИНС для определения начальных параметров остойчивости рыболовных судов, достигнув удовлетворительных результатов. Matulja и др. [5] сосредоточились на выборе оптимального винта судна с использованием ИНС, демонстрируя эффективность модели на предварительном этапе проектирования. Kim и др. [6] были применены искусственные нейронные сети для эффективной классификации обшивочных панелей корпуса судна (hull plates) на ранних этапах проектирования с целью оптимизации процесса формообразования и производства. В совокупности эти исследования подчёркивают потенциал ИНС для повышения точности прогнозов, эффективности расчётов и скорости разработки судовых форм за счёт автоматизации сложных этапов, которые традиционно опираются на эмпирические методы.

Материалы и методы

1. Сбор данных и предварительная обработка

Скорость и грузоподъёмность судна относятся к проектным параметрам, определяющим эксплуатационные требования судовладельца. На этапе предварительного (концептуального) проектирования судостроители опираются на характеристики корпуса (коэффициенты полноты, обводов, флотируемости и др.), а также задают главные размерения судна: наибольшую длину (LOA), длину между перпендикулярами (LBP), ширину (B) и осадку (T). Учитывая многопараметричность и динамичность проектного процесса, применяются методы оптимизации, обеспечивающие высокое качество обоснования проектных решений [7].

В настоящей работе использованы данные о 1700 рыболовных судах, собранные из реестра Российского морского регистра судоходства (rs-class.org). Для повышения достоверности набора проведена предварительная обработка: удаление «сестринских» судов и нормали-

зация данных. Статистические данные по девяти судам приведены в табл. 1, а диапазоны их изменчивости – в табл. 2.

Таблица 1 / Table 1

Основные данные выбранных судов
Key data of selected vessels

Номер ИМО	Дедвейт, т	Водоизмещение, т	Длина расчётная, м	Ширина, м	Высота борта, м	Осадка, м	Скорость, м/с	Мощность ГД, кВт
8411085	1796	4947	85	15.92	10	5.67	15.7	3825
8422759	690	2470	55	13.82	9.2	5.22	12.9	882
8228464	414	1220	50.3	9.95	5	4.14	12	852
8330712	207	781	39.37	9.47	5.13	3.77	11.5	588
8423571	88	327	29.98	7.1	3.66	2.9	9	224
8228232	30	174	22	7	3.3	2.39	9.5	221
8228438	5872	8026	134.2	17	6.4	4.09	10.9	882
8228701	414	1220	50.29	9.95	5	4.14	12	853
8331596	30	174	22	7	3.3	2.39	9.5	220

Таблица 2 / Table 2

Диапазон изменяемости основных данных выбранных судов
Range of variability of key data for selected vessels

Главные размерения	Мин	Макс	Среднее значение
Дедвейт, т	23	4709	679.69
Водоизмещение, т	155	10047	1984.77
Длина наибольшая, м	21.3	115	53.52
Ширина, м	5.5	19.03	10.95
Высота борта, м	2.5	12.22	6.38
Осадка, м	1.9	11.77	4.27
Скорость, м/с	8	16.1	12.07
Мощность ГД, кВт	110	3825	1092.87

Корреляционный анализ

Корреляционный анализ – это статистический метод, направленный на выявление закономерностей и тенденций в наборе данных. Более того, корреляция используется для оценки силы и направления связи между двумя или более переменными, для измерения силы линейной связи между двумя переменными.

Коэффициент корреляции служит метрикой, указывающей силу связи между зависимыми и независимыми переменными. Он измеряет линейную связь между двумя переменными и не зависит от единицы измерения, варьируясь от –1 до 1. Коэффициент, близкий к 0, означает слабую корреляцию, когда он близок к 1 или –1, означает сильную корреляцию.

В этом исследовании корреляция Пирсона была проведена на собранном наборе данных, и результаты можно визуализировать в таблице 3.

Таблица 3 показывает лучшую корреляцию между LOA, B, T, H и D, чем с Dw. По этой причине параметры D и Vs были сохранены в качестве входных данных для ИНС вместо Dw.

Таблица 3 / Table 3

Корреляция Пирсона предварительно обработанных данных
 Pearson correlation of preprocessed data

	<i>D_w</i>	<i>D</i>	<i>V_s</i>	<i>LOA</i>	<i>B</i>	<i>H</i>	<i>T</i>	<i>Ne</i>
<i>D_w</i>	1.000							
<i>D</i>	0.987	1.000						
<i>V_s</i>	0.771	0.802	1.000					
<i>LOA</i>	0.936	0.956	0.852	1.000				
<i>B</i>	0.899	0.933	0.900	0.956	1.000			
<i>H</i>	0.865	0.901	0.848	0.903	0.961	1.000		
<i>T</i>	0.790	0.820	0.846	0.841	0.895	0.881	1.000	
<i>Ne</i>	0.856	0.865	0.858	0.853	0.867	0.822	0.797	1.000

Примечание: *D_w* – Дедвейт, *D* – Водоизмещение, *V_s* – Скорость, *LOA* – Длина расчётная, *B* – Ширина, *H* – Высота борта, *T* – Осадка, *Ne* – Мощность ГД.

2. Искусственная нейронная сеть

Искусственные нейронные сети (ИНС) представляют собой алгоритмы машинного обучения, вдохновлённые принципами работы человеческого мозга. Они принимают решения, моделируя поведение биологических нейронов, что позволяет им распознавать явления, оценивать альтернативы и делать выводы [8, 9]. Благодаря способности точно аппроксимировать сложные нелинейные функции ИНС широко применяются в медицине, инженерии и информатике [10] и становятся перспективным инструментом кораблестроения.

Нейронная сеть состоит из взаимосвязанных элементов, называемых искусственными нейронами, концептуально моделирующих работу нейронов мозга [11]. Эти элементы соединены между собой связями, аналогичными биологическим синапсам. Каждый нейрон получает входные сигналы, обрабатывает их с помощью нелинейной функции активации и передаёт выходной сигнал другим нейронам. Сигналы представляют собой действительные числа, а их сила определяется весами, которые настраиваются в процессе обучения [12].

Правильный выбор топологии сети – то есть структуры связей между нейронами – имеет решающее значение для получения модели, способной к обобщению. Одна из часто возникающих проблем – переобучение, при котором сеть слишком хорошо запоминает обучающие данные и теряет способность обобщать [13]. Это можно устранить с помощью валидационного набора данных, увеличения объёма обучающей выборки или упрощения архитектуры сети.

Наиболее распространённым методом обучения является алгоритм обратного распространения ошибки (backpropagation), основанный на методе градиентного спуска. В этом алгоритме веса корректируются на основе ошибки между фактическим и ожидаемым выходом сети [14]. Основная цель обучения – минимизация функции потерь, которая при решении задач регрессии чаще всего оценивается с использованием метрик средней квадратичной ошибки (MSE) и корня средней квадратичной ошибки (RMSE) [15].

Алгоритм Левенберга – Марквардта (LM) сочетает два численных алгоритма минимизации: метод градиентного спуска и метод Гаусса – Ньютона. В методе градиентного спуска сумма квадратичных ошибок уменьшается путём обновления коэффициентов в направлении наискорейшего спуска [16]. В методе Гаусса – Ньютона сумма квадратичных ошибок уменьшается, предполагая, что функция наименьших квадратов локально квадратична по коэффициентам. Минимум этой квадратичной функции находится итерационным процессом, что обеспечивает постепенное снижение ошибки. Метод Левенберга – Марквардта ведёт себя, скорее, как метод градиентного спуска, когда коэффициенты далеки от их оптимального значения, и, скорее, как метод Гаусса – Ньютона, когда коэффициенты близки к их оптимальному значению.

Масштабированный метод сопряжённых градиентов (SCG) относится к классу методов сопряжённых градиентов, которые показывают сверхлинейную сходимость в большинстве задач. Он разработан, чтобы избежать времязатратного поиска по линии, сочетая подход области доверия модели, используемый в методе Левенберга – Марквардта, с подходом сопряжённых градиентов [17].

В данной работе алгоритм Левенберга – Марквардта применяется к задаче обучения многослойной сети. Типичная нейронная сеть показана на рисунке 1.




Рис. 1. Типичная нейронная сеть

Fig. 1. Typical neural network

Первым шагом в алгоритме обратного распространения является прямое распространение. В прямом распространении входные значения умножаются на веса для получения выходных данных нейронной сети [18].

$$Net_j = W_{0j} + \sum_{i=1}^n x_i \cdot W_{ij}, \quad (1)$$

$$выход_j = f(Net_j), \quad (2)$$

$$Net_k = W_{0k} + \sum_{j=1}^n \text{выход}_j \cdot W_{jk}, \quad (3)$$

$$\text{выход}_k = f(Net_k), \quad (4)$$

$$Net_l = W_{0l} + \sum_{k=1}^n \text{выход}_k \cdot W_{kl}, \quad (5)$$

$$\text{выход}_l = f(Net_l), \quad (6)$$

где веса W_{ij} определяют связи между входными нейронами и скрытыми нейронами j , веса W_{jk} определяют связи между скрытым слоем j и скрытым слоем k , веса W_{kl} определяют связи между скрытым слоем k и выходным слоем l . Значение x_i представляет собой входное значение, n – это количество входов для нейрона, выход j – значение выхода для скрытых узлов j , output – значение выхода для скрытых узлов k , n – это количество нейронов в скрытых слоях, выход l – значение выхода для выходных узлов. Веса w_{ij} , w_{jk} и w_{kl} являются смещениями.

Вес W_{ij} – весовые коэффициенты, которые соединяют каждый входной нейрон с каждым нейроном в первом скрытом слое.

Вес W_{jk} – весовые коэффициенты, которые соединяют каждый нейрон в первом скрытом слое с каждым нейроном во втором скрытом слое.

Вес W_{kl} – весовые коэффициенты, которые соединяют каждый нейрон в последнем скрытом слое с каждым нейроном в выходном слое.

Значение x_i – значение входного сигнала, подаваемого на входной нейрон.

Значение выхода для скрытых узлов (выход j и выход k) – это значения, которые скрытые нейроны передают далее в сеть.

Количество нейронов в скрытых слоях (n) – это количество нейронов в каждом скрытом слое.

Значение выхода для выходных узлов (выход l) – это конечные выходные значения, которые нейронная сеть генерирует.

Смещающие веса (w_{ij} , w_{jk} и w_{kl}) – это дополнительные весовые коэффициенты, которые используются для настройки порога активации нейронов.

Затем выход передаётся через функцию активации для получения конечного выхода нейронной сети. Функция гиперболического тангенса и функция `purelin` использовались в качестве функций активации в скрытом слое и выходном слое соответственно для этого исследования, а общие определения выражаются следующими уравнениями:

$$\text{purelin}(x) = x, \quad (7)$$

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (8)$$

После получения выходных данных мы вычисляем ошибку между прогнозируемым и фактическим выходными данными с помощью функции потерь. Наконец, получаем новые значения весов:

$$\delta_l = f'(\text{выход}_l)(t_l - o_l), \quad (9)$$

$$\delta_k = f'(\text{выход}_k) \cdot \sum_{l=1}^n w_{kl} \cdot \delta_l, \quad (10)$$

$$\delta_j = f'(\text{выход}_j) \cdot \sum_{k=1}^n w_{jk} \cdot \delta_k, \quad (11)$$

$$w_{ij}(n+1) = w_{ij}(n) + \alpha \delta_j(\text{выход}_j) + \beta(\Delta w_{ij}), \quad (12)$$

$$w_{jk}(n+1) = w_{jk}(n) + \alpha \delta_k(\text{выход}_k) + \beta(\Delta w_{jk}), \quad (13)$$

$$w_{kl}(n+1) = w_{kl}(n) + \alpha \delta_l(\text{выход}_l) + \beta(\Delta w_{kl}), \quad (14)$$

где альфа (α) – это скорость обучения, а бета (β) – коэффициент момента. Скорость обучения контролирует, с какой скоростью алгоритм будет двигаться к минимальному значению градиента.

Коэффициент момента – это параметр в диапазоне от 0 до 1, используемый для увеличения скорости, с которой корректируются весовые коэффициенты.

Эти процедуры повторяются до тех пор, пока не будет достигнуто желаемое значение ошибки.

Архитектура предлагаемой нейронной сети представлена на рисунке 2. Она включает входной слой с двумя параметрами (водоизмещение и скорость судна), скрытый слой и выходной слой, содержащий четыре главных размерения корпуса (длину расчётную L_{OA} , ширину B , высоту борта H и осадку T).




Рис. 2. Архитектура предлагаемой нейронной сети

Fig. 2. Architecture of the proposed neural network

3. Метрики ошибок прогнозирования

Функция производительности сети была определена среднеквадратичной ошибкой (MSE), которая представлена в уравнении (15). Для сравнения использовался статистический подход среднего абсолютного процентного отклонения (MAPE), представленный в уравнении (16).

Среднеквадратичная ошибка рассчитывается как среднее арифметическое квадратов разностей между предсказанными и фактическими значениями. Формула MSE представлена следующим образом:

$$MSE = \frac{1}{n} \sum_{i=1}^N (t_i - o_i)^2 \quad (15)$$

Среднее абсолютное процентное отклонение рассчитывается как среднее арифметическое абсолютных значений процентных ошибок между предсказанными и фактическими значениями. Формула MAPE представлена следующим образом:

$$MAPE = \frac{1}{n} \sum_{i=1}^N \left| \frac{t_i - o_i}{o_i} \right| * 100, \quad (16)$$

где t_i – фактическое значение;
 o_i – предсказанное значение;
 N – количество наблюдений.

Реализация

Методология, реализованная в данном исследовании, изображена на рисунке 3. Она разделена на три этапа: сбор и предварительная обработка данных, обучение модели, оценка модели и получение результатов. В текущем исследовании искусственная нейронная сеть (ИНС) была обучена и протестирована с помощью программного обеспечения MATLAB. Набор данных для валидации использовался для решения проблемы переобучения, и максимальное количество ошибок валидации было установлено на 1000. Алгоритм обучения с обратным распространением ошибки и алгоритм Левенберга – Марквардта (LM) были применены к одному скрытому слою. Для данного исследования было собрано 1714 образцов данных, но только 590 из них были сохранены после предварительной обработки.

413 образцов использовались для обучающего набора, 118 образцов – для набора данных валидации, 59 образцов – для тестового набора. Обучающий набор данных используется только для обучения сети, в то время как тестовый набор данных используется для определения производительности сети, или соответственно 70, 20 и 10% от набора данных. Набор данных валидации используется для предотвращения запоминания сети. В процессе обучения скорость обучения и коэффициент момента были приняты равными 0.01 и 0.1 соответственно. Масштабирование признаков методом min-max было применено согласно уравнению (17) как на входные, так и на выходные данные обучающих и валидационных наборов. Масштабирование данных используется для приведения всех значений в диапазон [0,1]. Функция logsig и функция relu были использованы в качестве функций активации в скрытом слое и выходном слое соответственно. Дополнительный анализ был выполнен для определения оптимального количества нейронов в скрытом слое.

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (17)$$

где x' – нормализованное значение;
 x – исходное значение;
 $x_{\max}$ – наибольшее значение данного набора;
 $x_{\min}$ – наименьшее значение данного набора.




Рис. 3. Методологическая основа настоящего исследования

Fig. 3. Methodological framework of the present study

Результаты

Целью данного исследования было разработать модель искусственной нейронной сети (ИНС) для прогнозирования главных размерений рыболовных судов на стадии предварительного проектирования. Скорость судна и водоизмещение использовались в качестве входных параметров, в то время как общая длина (LOA), ширина (B), высота борта (H) и осадка (T) использовались в качестве выходных параметров.

Для получения выходных значений, максимально соответствующих собранным данным, было протестировано различное количество нейронов (от 1 до 15) в скрытом слое. В таблице 4 представлены значения среднеквадратичной ошибки (MSE) для всех наборов данных с разным количеством скрытых нейронов.

Разработанная модель ANN с 14 скрытыми нейронами в скрытом слое показала высокую способность к прогнозированию основных характеристик рыболовных судов с минимальным значением MSE 0.633 (табл. 4). Эта конфигурация обеспечивает точные и надёжные прогнозы, делая модель ценным инструментом для стадии предварительного проектирования рыболовных судов.

Таблица 4 / Table 4

Производительность разработанной модели
Performance of the developed model

Число нейронов в скрытом слое	MSE
1	1.471
2	1.458
3	1.170
4	1.104
5	0.776
6	0.721
7	0.813
8	0.714
9	0.641
10	0.744
11	0.720
12	0.679
13	0.639
14	0.633
15	0.641

Как показано в таблице 5, средние значения среднего абсолютного процентного отклонения (MAPE) для ошибок модели составляют:

Длина наибольшая (L): 0.00635.

Ширина (B): 0.00297.

Высота борта (H): 0.00841.

Осадка (T): 0.00724.

Аналогично средние значения MAPE для набора данных составляют:

Обучающий набор: 0.0000233.

Валидационный набор: 0.0004369.

Тестовый набор: 0.014331.

Валидационный набор продемонстрировал наибольшее значение MAPE по ширине (B), тогда как в обучающем наборе минимальное значение этой метрики было зафиксировано по наибольшей длине (L). В целом модель продемонстрировала приемлемые значения ошибок, хотя осадка (T) имела более высокое значение MAPE.

Таблица 5 / Table 5

Значения MAPE сети

Mean absolute percentage error (MAPE) values of the network

MAPE	Обучающий набор	Валидационный набор	Тестовый набор	В целом
Длина наибольшая, м	9.30E-05	0.007836	0.011116	6.35E-03
Ширина, м	8.83E-08	0.006767	0.002132	2.97E-03
Высота борта, м	1.69E-08	0.001110	0.024120	8.41E-03
Осадка, м	1.43E-08	0.001765	0.019955	7.24E-03
Среднее значение	2.33E-05	0.004369	0.014331	6.24E-03

На рисунке 4 изображён график регрессии между прогнозом модели ИНС и фактическими данными о судне. Оценённые коэффициенты детерминации (R) для обучающего, валидационного, тестового наборов и общего процесса составили соответственно 0.99918, 0.99888, 0.9988 и 0.99908, что указывает на высокий уровень согласованности между фактическими и ожидаемыми значениями. Эти результаты подчёркивают надёжность модели.




Рис. 4. Графики регрессии модели разработанной сети:

a – обучения; b – проверки; c – тестирования; d – общего процесса

Fig. 4. Model regression plots of the developed network: a – training set; b – validation set; c – testing set; d – overall performance

При анализе графика производительности построенной модели, изображённого на рис. 5, становится очевидно, что оптимальная валидационная производительность была достигнута на эпохе 125, среднеквадратичная ошибка (MSE) составила 1.2502.




Рис. 5. График производительности разработанной сети

Fig. 5. Performance plot of the developed network

На рис. 6 показана гистограмма ошибок, где синие, зелёные и красные полосы обозначают данные обучения, данные проверки и данные тестирования соответственно. Значение ошибки указывает на разницу между фактическим и прогнозируемым значением. Оранжевая линия показывает линию нулевой ошибки. Из рис. 6 можно увидеть, что наибольшая часть данных совпала с линией нулевой ошибки. Большая часть ошибок варьировалась от $-1,208$ до $+0,7628$.




Рис. 6. Гистограмма ошибок разработанной модели ИНС

Fig. 6. Error histogram of the developed ANN model

Таблица 6 иллюстрирует часть фактических и прогнозируемых значений выходных параметров для нескольких образцов тестового набора, не использованных для обучения. Из таблицы видно, что фактические значения выходных параметров близки к прогнозируемым значениям.

Таблица 6 / Table 6

Фактические и прогнозируемые значения выходов

Actual and predicted output values

Длина наибольшая, м		Ширина, м		Высота, м		Осадки, м	
фактическое	прогноз	Фактическое	прогноз	Фактическое	прогноз	Фактическое	прогноз
50.29	49.56	9.95	10.03	6	6.04	4.29	4.36
47.92	47.72	10.72	10.77	6	6.01	4.3	4.37
92.05	91.8	15.2	15.25	9.7	9.71	5.7	5.62
85	84.95	15.92	15.36	10	10.08	5.67	5.87
73.11	72.39	13.63	13.81	9.55	9.51	5.3	5.28
55	55.15	13.82	13.23	9.2	8.84	5.22	5.04

На рисунке 7 представлено соответствие между фактическими и прогнозируемыми значениями параметров L, B, H и T в зависимости от D. Разработанная модель показывает более точное соответствие целевым значениям, особенно для размерений L, B и H. Отмечается, что наилучшая точность результатов достигнута по наибольшей длине L.




Рис. 7. Графики зависимости главных размерений корпуса от водоизмещения:
a – длина L; b – ширина B; c – высота H; d – осадка T

Fig. 7. Prediction plots of main hull dimensions as functions of displacement:
a – length L; b – breadth B; c – height H; d – draft T

Закключение

В данном исследовании была поставлена задача разработать искусственную нейронную сеть для прогнозирования основных характеристик рыболовного судна. Определение главных размерений судна на стадии предварительного проектирования является критически важным и сложным процессом для судостроителей. Традиционно эти параметры устанавливаются с использованием статистических методов или эмпирических формул на основе данных о существующих судах, что делает предварительное проектирование очень сложным и трудоёмким процессом.

Исследование показало, что конфигурация нейронной сети с 14 скрытыми нейронами демонстрирует лучшие прогностические характеристики. Для разработки модели использовались данные, собранные с 590 рыболовных судов с исключением сестринских судов. Для оценки производительности модели использовалась среднеквадратичная ошибка (MSE), а для оценки прогнозов, сделанных моделью, использовалась средняя абсолютная процентная ошибка (MAPE). Выводы исследования могут быть суммированы следующим образом:

- средняя абсолютная процентная ошибка (MAPE) для общего набора данных составила 0.00635, 0.00297, 0.00841 и 0.00724 соответственно для размерений L, B, H и T;
- коэффициенты корреляции были получены такие: 0.99918, 0.99888, 0.9988 и 0.99908 соответственно для обучающего, валидационного, тестового и всех наборов данных, что свидетельствует о высоком уровне согласованности разработанной модели;
- оптимальная валидационная производительность была достигнута при 125-ой итерации обучения: среднеквадратичная ошибка (MSE) составила 1,2502.

Разработанная и обученная нейронная сеть продемонстрировала приемлемый уровень точности, что подтверждает её потенциал в рассматриваемой области. Однако текущая архитектура модели всё ещё обладает резервами для оптимизации. В связи с этим требуется проведение дополнительных исследований и совершенствование методики с целью повышения эффективности и способности к обобщению.

ВКЛАД АВТОРОВ | CONTRIBUTION OF THE AUTHORS

Д.В. Фомин – разработка концепции и дизайна исследования; А.В. Поляков – подготовка и редактирование текста; И.О. Шолыгин, И.А. Рябов – сбор данных; анализ и интерпретация результатов. Все авторы прочитали и одобрили окончательный вариант рукописи.

D.V. Fomin – development of the research concept and design; A.V. Polyakov – preparation and editing of the text, I.O. Sholygin, I.A. Ryabov – data collection; analysis and interpretation of the results. All the authors have read and approved the final version of the manuscript.

КОНФЛИКТ ИНТЕРЕСОВ | DISCLOSURE

Авторы заявляют об отсутствии конфликта интересов.
The authors declare no conflict of interest.

СПИСОК ИСТОЧНИКОВ

1. Эванс Дж.Х. Основные концепции проектирования // *Journal of the American Society of Naval Engineers*. 1959. Т. 71, № 4. С. 671–678. (англ.). <https://doi.org/10.1111/j.1559-3584.1959.tb01836.x>
2. Папаниколау А. Методология предварительного проектирования судов. Dordrecht: Springer, 2014. 625 с. (англ.). <https://doi.org/10.1007/978-94-017-8751-2>
3. Клаусен Х.Б., Лютцен М., Фрис-Хансен А., Бьёрнебу Н.К. Байесовские и нейронные сети для предварительного проектирования судов // *Marine Technology*. 2001. Т. 38, № 4. С. 268–277. (англ.). <https://doi.org/10.1016/B978-008043950-1/50044-2>
4. Алкан А., Гюлез К., Йылмаз Х. Проектирование надёжной архитектуры нейронной сети для определения параметров начальной остойчивости рыболовных судов // *Ocean Engineering*. 2004. Т. 31, № 6–7. С. 761–777. (англ.). <https://doi.org/10.1016/j.oceaneng.2003.08.002>
5. Матуйя Д., Деалла Р., Барбир О. Применение искусственной нейронной сети для выбора максимально эффективного гребного винта судна // *Journal of Ship Production and Design*. 2010. Т. 26, № 3. С. 199–205. (англ.).
6. Ким С., Мун Б., Ким Д. Оптимальное проектирование системы проектирования судна с использованием метода нейронных сетей на этапе начального проектирования обшивки корпуса // *KSME International Journal*. 2004. Т. 18, № 11. С. 1923–1931. (англ.).
7. Цуй Ю., Туран О., Сайер П. Оптимизация проектирования судов с помощью алгоритмов машинного обучения // *Computer-Aided Design*. 2012. Т. 44, № 3. С. 186–195. (англ.). <https://doi.org/10.1038/nature14539>
8. ЛеКан Й., Бенджио Й., Хинтон Г. Глубокое обучение // *Nature*. 2015. Т. 521, № 7553. С. 436–444. (англ.). <https://doi.org/10.1038/nature14539>
9. Гудфеллоу И., Бенджио Й., Курвилл А. Глубокое обучение. Cambridge (MA): MIT Press, 2016. 800 р. (англ.).
10. Шмидхубер Й. Глубокое обучение в нейронных сетях // *Neural Networks*. 2015. Т. 61. С. 85–117. (англ.). <https://doi.org/10.1016/j.neunet.2014.09.003>
11. Хейкин С. Нейронные сети и методы машинного обучения. Upper Saddle River: Prentice Hall, 2009. 906 р. (англ.).
12. Хорник К., Стинчкомб М., Уайт Х. Многослойные сети – универсальные аппроксиматоры // *Neural Networks*. 1989. Т. 2, № 5. С. 359–366. (англ.). [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
13. Чжан Ц., Уоллес Б. Анализ чувствительности свёрточных нейронных сетей для классификации предложений // *Proceedings of the 8th International Joint Conference on Natural Language Processing (IJCNLP-2017)*. 2017. С. 253–263. (англ.). <https://aclanthology.org/I17-1026.pdf>
14. Вербос П.Дж. Обратное распространение во времени: что это такое и как это делать // *Proceedings of the IEEE*. 1990. Т. 78, № 10. С. 1550–1560. (англ.). <https://ieeexplore.ieee.org/document/58337>
15. Шоле Ф. Глубокое обучение на Python. Manning, 2018. 384 р. (англ.).
16. Гэвин Х.П. Алгоритм Левенберга – Марквардта для нелинейных задач наименьших квадратов. Durham: Duke University, 2024. 23 с. (англ.). <https://people.duke.edu/~hpgavin/lm.pdf>
17. Мёллер М.Ф. Масштабированный метод сопряжённых градиентов для быстрого обучения // *Neural Networks*. 1993. Т. 6, № 4. С. 525–533. (англ.).
18. Аджитеш К. Алгоритм backpropagation в нейронных сетях // *Analytics Yogi*. 2023. Т. 1, № 1. С. 1–10. (англ.). <https://vitalflux.com/neural-network-back-propagation-python-examples/>

REFERENCES

1. Evans J.H. Basic design concepts. *Journal of the American Society of Naval Engineers*, 1959, vol. 71, no. 4, pp. 671–678. <https://doi.org/10.1111/j.1559-3584.1959.tb01836.x>

2. Papanikolaou A. Ship design: methodologies of preliminary. Design: Springer, 2014. 625 p. <https://doi.org/10.1007/978-94-017-8751-2>
3. Clausen H.B., Lutzen M., Fries-Hansen A., Bjerneboe N.K. Preliminary design of container ships using neural networks. *Marine Technology*, 2001, vol. 38, no. 4, pp. 268–277. <https://doi.org/10.1016/B978-008043950-1/50044-2>
4. Alkan A., Gulez K., Yilmaz H. Design of a robust neural network structure for determining initial stability particulars of fishing vessels. *Ocean Engineering*, 2004, vol. 31, no. 6–7, pp. 761–777. <https://doi.org/10.1016/j.oceaneng.2003.08.002>
5. Matulja D., Dealla R., Barbir O. Application of an artificial neural network to the selection of a maximum efficiency ship screw propeller. *Journal of Ship Production and Design*, 2010, vol. 26, no. 3, pp. 199–205. <https://doi.org/10.5957/jspd.2010.26.3.199>
6. Kim S., Moon B., Kim D. Optimum design of ship design system using neural network method in initial design of hull plate. *KSME International Journal*, 2004, vol. 18, no. 11, pp. 1923–1931. <https://doi.org/10.1007/BF02990434>
7. Cui Y., Turan O., Sayer P. Learning-based ship design optimization approach. *Computer-Aided Design*, 2012, vol. 44, no. 3, pp. 186–195. <https://doi.org/10.1038/nature14539>
8. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, no. 7553, pp. 436–444. <https://doi.org/10.1038/nature14539>
9. Goodfellow I., Bengio Y., Courville A. Deep learning. Cambridge (MA): MIT Press, 2016. 800 p.
10. Schmidhuber J. Deep learning in neural networks: overview. *Neural Networks*, 2015, no. 61, pp. 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
11. Haykin S. Neural Networks and Learning Machines. Upper Saddle River: Prentice Hall, 2009. 906 p.
12. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 1989, vol. 2, no. 5, pp. 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
13. Zhang C., Wallace B. Sensitivity analysis of CNNs for sentence classification. *Proceedings of the 8th International Joint Conference on Natural Language Processing (IJCNLP-2017)*, 2017, pp. 253–263. <https://aclanthology.org/I17-1026.pdf>
14. Werbos P.J. Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*, 1990, vol. 78, no. 10, pp. 1550–1560. <https://ieeexplore.ieee.org/document/58337>
15. Chollet F. Deep Learning with Python. Manning, 2018. 384 p.
16. Gavin H.P. The Levenberg – Marquardt algorithm for nonlinear least squares. Durham: Duke University, 2024. 23 p. <https://people.duke.edu/~hpgavin/lm.pdf>
17. Møller M.F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 1993, vol. 6, no. 4, pp. 525–533.
18. Ajitesh K. Backpropagation algorithm in neural networks. *Analytics Yogi*, 2023, vol. 1, no. 1, pp. 1–10. <https://vitalflux.com/neural-network-back-propagation-python-examples/>

ИНФОРМАЦИЯ ОБ АВТОРАХ | INFORMATION ABOUT THE AUTHORS

Китио Герман – аспирант кафедры «Инновационное судостроение и технологии освоения шельфа», Севастопольский государственный университет (Севастополь, Российская Федерация),

✉ hermannkitio94@gmail.com

Hermann Kitio, Graduate Student, Department of “Innovative Shipbuilding and Offshore Development Technologies”, Sevastopol State University (Sevastopol, Russian Federation).

Душко Вероника Ростиславовна – кандидат технических наук, доцент, проректор по образовательной деятельности, заведующий кафедрой «Инновационное судостроение и технологии освоения шельфа», Севастопольский государственный университет (Севастополь, Российская Федерация),

✉ evrdushko@sevsu.ru

Veronika R. Dushko, Candidate of Engineering Sciences, Associate Professor, Vice-Rector for Educational Activities, Head of the Department of “Innovative Shipbuilding and Offshore Development Technologies”, Sevastopol State University (Sevastopol, Russian Federation).

Несин Даниил Юрьевич – кандидат технических наук, доцент кафедры «Инновационное судостроение и технологии освоения шельфа», Севастопольский государственный университет (Севастополь, Российская Федерация),

✉ DaniilNesin@mail.ru

Daniil Yu. Nesin, Candidate of Engineering Sciences, Associate Professor at the Department of “Innovative Shipbuilding and Offshore Development Technologies”, Sevastopol State University (Sevastopol, Russian Federation).

Статья поступила в редакцию / Received: 15.05.2025.

Доработана после рецензирования / Revised: 18.08.2025.

Принята к публикации / Accepted: 24.09.2025.