



## ВОЗМОЖНОСТЬ ИСПОЛЬЗОВАНИЯ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ ОСТАТОЧНОГО СОПРОТИВЛЕНИЯ КОРПУСА СУДНА НА РАННИХ ЭТАПАХ ПРОЕКТИРОВАНИЯ

Е.А. Чуреев,

директор научно-исследовательского центра судостроения

e-mail: e.chureev@klgtu.ru

ФГБОУ ВО «Калининградский государственный  
технический университет»



В.И. Пинчук, студент

email: vladislav.pinchuk@klgtu.ru

ФГБОУ ВО «Калининградский государственный  
технический университет»

В данной статье рассматривается применимость методов машинного обучения для интерполяции значений серийной диаграммы, на примере серии Е.В. Маслюка для маломерных рыболовных судов с упрощенными обводами. С использованием нейронных сетей для задач прогнозирования модель была обучена и оптимизирована методом поиска по сетке (Grid Search) и достигла ошибки валидации 1,01% и обучения 1,49%. Точность модели была оценена с учетом допустимой ошибки 3%, общепринятой в инженерных расчетах. Результатом исследования стала архитектура нейронной сети с точностью 98,51% на валидационном наборе данных, подчеркивающая потенциал использования машинного обучения в ранних расчетах остаточного сопротивления корпуса судна.

**Ключевые слова:** *Машинное обучение, серийные диаграммы, остаточное сопротивление, промысловые суда*

### ВВЕДЕНИЕ

В настоящее время существует несколько методов определения остаточного сопротивления корпуса судна: CFD расчет, испытания в оптовом бассейне и серийные диаграммы. Использование CFD расчета требует значительных вычислительных мощностей, соответствующих компетенций, однако не всегда способно дать точный результат и учесть все факторы [1]. Самым точным методом расчета являются испытания в оптовом бассейне, однако данный способ отличается дороговизной и требует значительных временных затрат. В свою очередь серийные диаграммы представляют собой результаты систематизированных модельных испытаний с вариацией отношений главных размеренной и коэффициентов полноты. Недавний прогресс, достигнутый в области машинного обучения с так называемым глубоким обучением, обеспечивает большую гибкость и эффективность для структурирования и обработки данных [2]. В судостроении методы машинного обучения только начинают применяться, в частности при расчете винтов на изгиб и мониторинга корпуса судна [3-4].

В свою очередь серийные диаграммы имеют достаточный объем данных для возможности применения методов машинного обучения, которые можно использовать для получения интерполяций промежуточных значений.

## **ОБЪЕКТ ИССЛЕДОВАНИЯ**

Методы определения остаточного сопротивления корпуса судна, включая применение серийных диаграмм и машинного обучения для интерполяции значений.

## **ЦЕЛЬ И ЗАДАЧИ ИССЛЕДОВАНИЯ**

Исследовать возможность применения полносвязных нейронных сетей для интерполяции значений серийных диаграмм в расчете остаточного сопротивления судна

Задачи исследования:

- Сбор и разметка данных для обучения;
- Проектирования архитектуры нейронной сети;
- Обучение и тестирование модели;
- Анализ точности модели на всем промежутке целевой функции.

## **РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ**

Для исследования была выбрана серия Е.В. Маслюка для маломерных рыболовных судов с упрощенными обводами [5]. Целевой функцией в рассматриваемой серии является значение удельного остаточного сопротивления  $R_0$  (кг/т). Входными данными в данную серию являются:

Отношение длины к ширине -  $L/B$

Призматический коэффициент -  $\phi$

Число Фруда -  $Fr$

Отношение ширины к осадке -  $B/T$

Сбор датасета осуществлялся с помощью программы Get Data Graph Digitazer (рис.1). Итоговый объем датасета составил 9165 точек.

Архитектура нейронной сети реализована на языке python и проектировалась методом поиска по сетке (Grid Search) на языке python, в котором алгоритм поиска принимает на вход модель и допустимые значения гиперпараметров (сетку гиперпараметров), и вычисляет оценки качества модели для всевозможных наборов значений гиперпараметров. В конце работы алгоритм возвращает модель, для которой величина ошибки минимальна. [6] Гиперпараметрами для оптимизации выступали: функция активации, количество слоев в "скрытых" слоях, количество "скрытых" слоев.

Таким образом гиперпараметры используемой нейронной сети:

- Оптимизатор - Adam
- Learning rate - 0.001
- Количество эпох обучения - 1000
- Количество скрытых слоев - 6
- Количество нейронов в скрытом слое – 200

- Функция активации – Elu/Relu
- Функция потерь – относительная ошибка
- Соотношение тренировочной выборки к валидационной – 3/1 (75% и 25%)

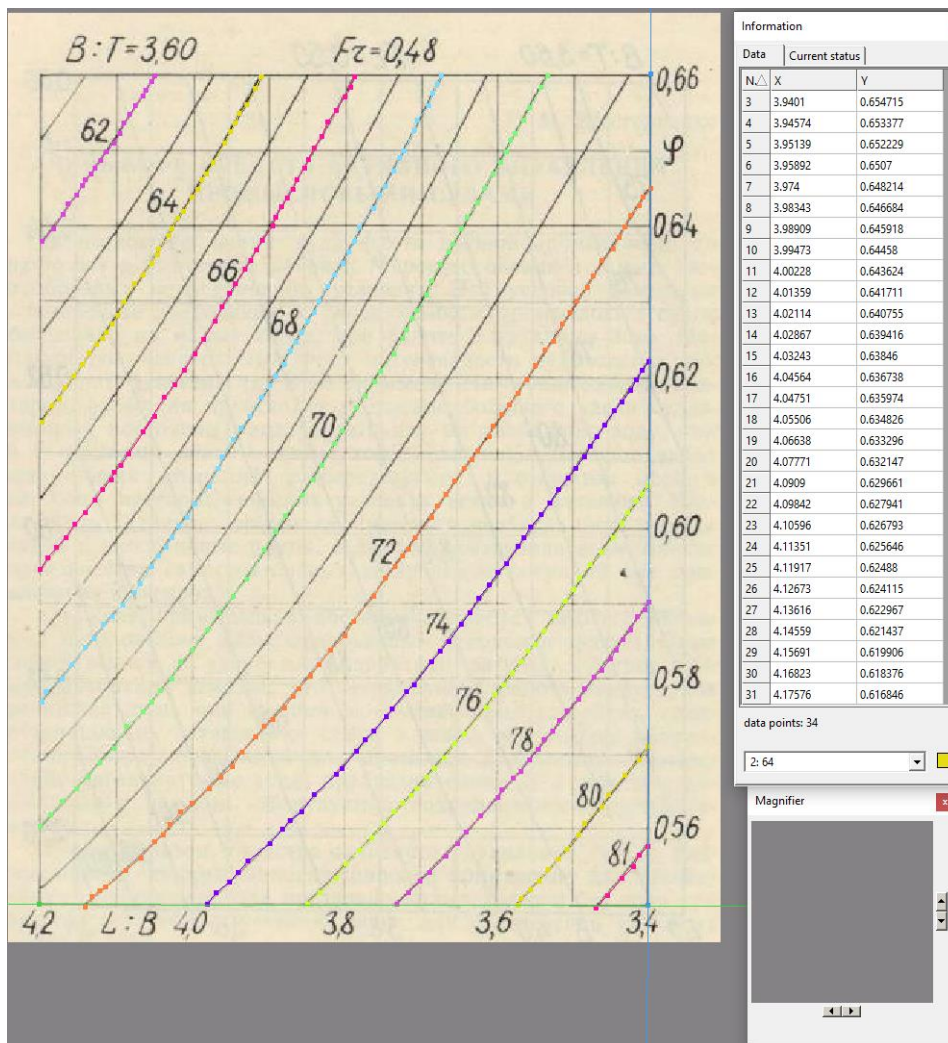


Рисунок 1 - Разметка данных в программе Get Data Graph Digitizer.

Код архитектуры представлен на рисунке 2.

```

checkpoint = ModelCheckpoint('best_model', monitor='val_loss', save_best_only=True)

model = keras.models.Sequential()

model.add(keras.layers.InputLayer(input_shape=[4]))
model.add(keras.layers.Dense(200, activation = 'elu'))
model.add(keras.layers.Dense(200, activation = 'relu'))
model.add(keras.layers.Dense(200, activation = 'elu'))
model.add(keras.layers.Dense(200, activation = 'elu'))
model.add(keras.layers.Dense(200, activation = 'relu'))
model.add(keras.layers.Dense(200, activation = 'elu'))
model.add(keras.layers.Dense(1, activation = 'elu'))

model.compile(optimizer = keras.optimizers.Adam(0.0001), loss='mean_absolute_percentage_error', metrics=['mean_absolute_percentage_error'])

X = df.loc[:, ['LB', 'f', 'Fr', 'BT']] # Вводные параметры
Y = df.loc[:, ['R']] # Целевые параметры

X_train, X_test, y_train, y_test = train_test_split(X, Y, train_size=0.75, random_state=1)

```

Рисунок 2 - Код архитектуры нейронной сети.

По результатам обучения, средняя ошибка на валидационной выборке составила 1.01%, а на обучающей 1.49%.

В качестве критериев оценки допустимой точности была принята максимальная допустимая погрешность 3%, как общепринятая допустимая ошибка в проведении инженерных расчетов на ранних этапах проектирования. Однако, для корректной оценки точности работы модели требуется рассматривать не только среднюю ошибку по всем значениям, но и точность прогнозирования на всем промежутке целевой функции.

Было выяснено, что значения, в которых модель допускает ошибку более 2% лежит в области  $R_0$  0-20, что отражено в виде точечной диаграммы на рисунке 3. Увеличение относительной ошибки на малых значениях целевой функции может быть обусловлено, малым количеством данных находящихся у кривых на краях допустимых значений используемой серийной диаграммы. В практике малые значения относительного остаточного сопротивления крайне редко соответствуют расчетным режимам плавания. Таким образом в большинстве случаев ошибка полученной модели не превышает 2% (рис.4).

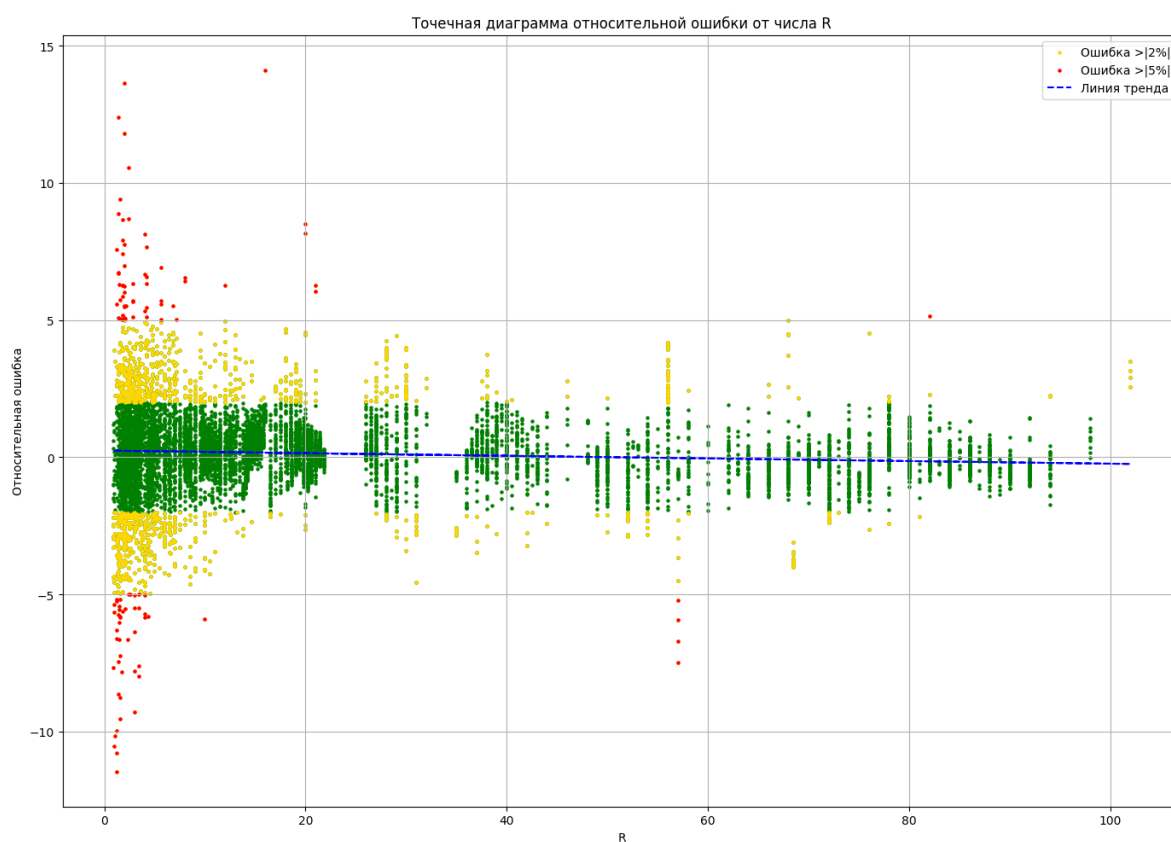


Рисунок 3 - Точечная диаграмма относительной ошибки модели от целевой функции.

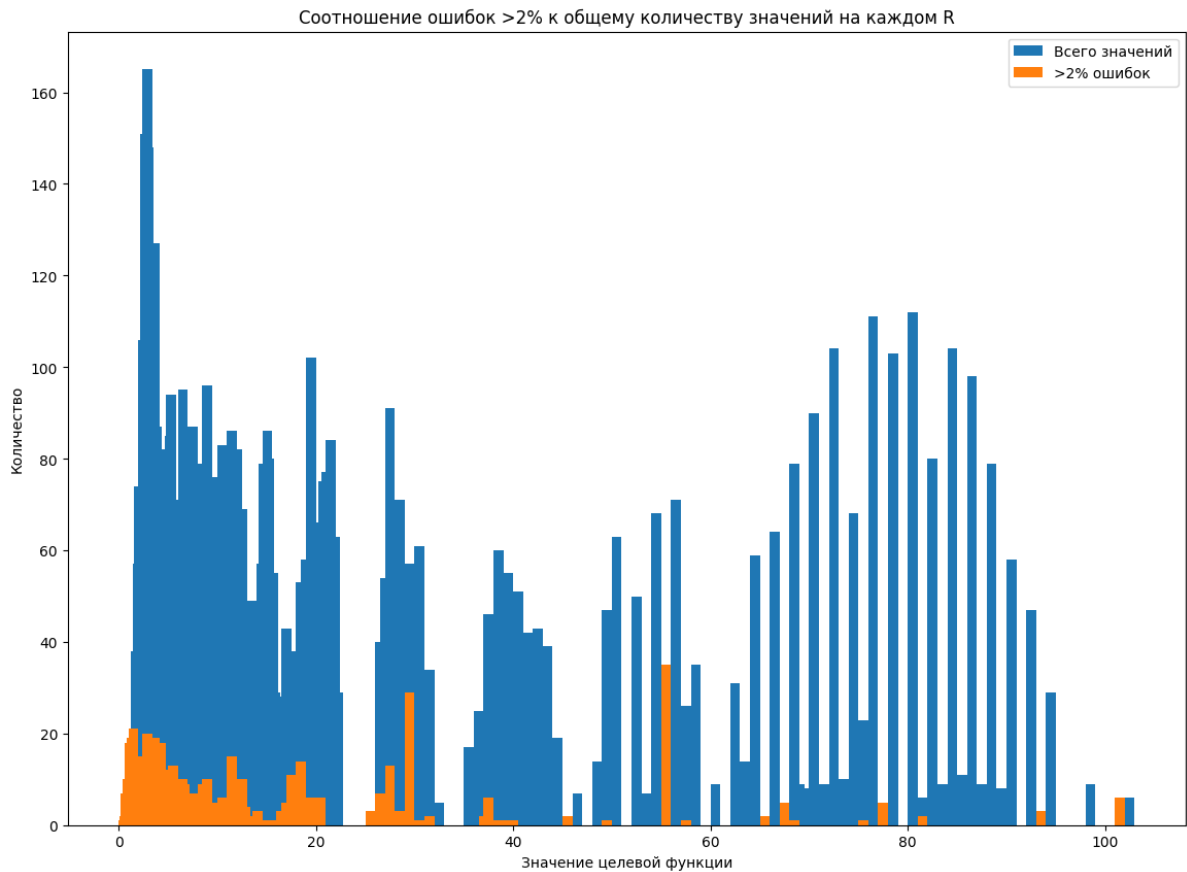


Рисунок 4 - Соотношение значений с относительной ошибкой более 2% к общему количеству значений целевой функции.

Результат работы модели представляет собой значение целевой функции, однако имеется возможность вывода массива значений, относящихся к конкретному графику рассматриваемой серии, что может также использоваться в качестве инструмента оценки точности модели и качества обучающих данных. На рисунке 5 представлена визуализация значений, полученная для  $B:T = 3.0$ ,  $Fr = 0.38$  в виде тепловой карты.

Из рисунков 5-6 можно заметить, что модель имеет ошибку в 4% в районе кривой со значением равным 13,8 в нижней части графика. Предполагается, что малое количество снятых данных с кривой имеет недостаточный вес, для получения более точных значений, что необходимо учитывать при подготовке данных для обучения подобных моделей.




Рисунок 5 - Тепловая карта интерполяций модели.




Рисунок 6 - Исходные данные серийной диаграммы.

### ЗАКЛЮЧЕНИЕ

В результате работы была спроектирована архитектура нейронной сети, точность которой составляет 98,51% на валидационной выборке. Проведен анализ относительной ошибки модели в зависимости от значения целевой функции. Выяснено, что наибольшую ошибку модель показывает на малых значениях целевой функции. Показан пример расчета, выполненный моделью на  $B:T = 3.0$ ,  $Fr = 0.38$ . Сделано предположение, что одним из путей повышения точности модели является количество снятых точек с кривой при подготовке данных для обучения. Полученные результаты могут использоваться для расчета остаточного сопротивления корпуса судна на ранних стадиях проектирования.

### СПИСОК ЛИТЕРАТУРЫ

1. Борусевич Валерий Олегович, Пустошный Александр Владимирович, Магаровский Вячеслав Валерьевич, Таранов Андрей Евгеньевич Соотношение расчетных и экспериментальных методов в современной гидродинамике судна // Труды Крыловского государственного научного центра. 2020. №2 (392). URL: <https://cyberleninka.ru/article/n/sootnoshenie-raschetnyh-i-eksperimentalnyh-metodov-v-sovremennoy-gidrodinamike-sudna> (дата обращения: 23.03.2024).

2. Столяров А.С., Раджабов Т.Р. РАЗВИТИЕ ИИ. ГЛУБОКОЕ И МАШИННОЕ ОБУЧЕНИЕ // Теория и практика современной науки. 2018. №8 (38). URL: <https://cyberleninka.ru/article/n/razvitie-ii-glubokoe-i-mashinnoe-obuchenie> (дата обращения: 04.03.2024).
3. Hase, A. A., & Chang, J. Implementation of Artificial Intelligence in Bending Analysis of Propeller/Fan Blade. In: Proceedings of the ASME 2021 30th Conference on Information Storage and Processing Systems: V001T02A005. Virtual, Online, June 2–3, 2021. ASME. DOI: 10.1115/ISPS2021-65267. URL: <https://asmedigitalcollection.asme.org/ISPS/proceedings-abstract/ISPS2021/84799/V001T02A005/1114136> (дата обращения 03.03.2024)
4. Moreira, L., & Guedes Soares, C. Neural network model for estimation of hull bending moment and shear force of ships in waves. Ocean Engineering, Volume 206, 2020, 107347. ISSN 0029-8018. DOI: 10.1016/j.oceaneng.2020.107347. URL: <https://doi.org/10.1016/j.oceaneng.2020.107347> (дата обращения 03.03.2024)
5. Е.В. Маслюк РАСЧЕТ СОПРОТИВЛЕНИЯ МАЛОТОННАЖНЫХ ПРОМЫСЛОВЫХ СУДОВ С УПРОЩЕННЫМИ ОБВОДАМИ КОРПУСА// Тр. КТИРПиХ. Вып. 93 «Мореходность судов». – Калининград 1981, с. 81-126.
6. Анафиев Айдер Сератович, Карюк Александр Сергеевич ОБЗОР ПОДХОДОВ К РЕШЕНИЮ ЗАДАЧИ ОПТИМИЗАЦИИ ГИПЕРПАРАМЕТРОВ ДЛЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ // ТВИМ. 2022. №2 (55). URL: <https://cyberleninka.ru/article/n/obzor-podhodov-k-resheniyu-zadachi-optimizatsii-giperparametrov-dlya-algoritmov-mashinnogo-obucheniya> (дата обращения: 04.03.2024).

#### POSSIBILITY OF USING MACHINE LEARNING TO DETERMINE THE RESIDUAL RESISTANCE OF THE SHIP HULL AT THE EARLY STAGES OF DESIGN

E.A. Chureev,  
Deputy director for science of the Shipbuilding research  
centere-mail: e.chureev@klgtu.ru

V.I. Pinchuk, student  
e-mail: vladislav.pinchuk@klgtu.ru  
Kaliningrad State Technical University

Kaliningrad State Technical University This article discusses the applicability of machine learning methods for interpolating the values of a serial diagram, using the example of the E.V. series. Maslyuk for small fishing vessels with simplified lines. Using neural networks for prediction tasks, the model was trained and optimized using the Grid Search method and achieved a validation error of 1.01% and a training error of 1.49%. The accuracy of the model was assessed taking into account the permissible error of 3%, generally accepted in engineering calculations. The result of the study was a neural network architecture with an accuracy of 98.51% on the validation data set, highlighting the potential of using machine learning in early calculations of residual resistance of a ship's hull.

**Key words:** Machine learning, serial diagrams, residual resistance, fishing vessels