

Научная статья

УДК 629.12 004.8

DOI 10.46845/1997-3071-2025-78-99-114

Адаптация модели искусственного интеллекта для определения проектных характеристик судна

Денис Дмитриевич Довгополик¹, Павел Романович Гришин², Николай Леонидович Великанов³, Андрей Андреевич Мушенков⁴✉

^{1,2,3,4} Калининградский государственный технический университет, Калининград, Россия

¹ AndryshaFF@yandex.ru

² pavel.grishin@klgtu.ru

³ nikolaj.velikanov@klgtu.ru, <https://orcid.org/0000-0001-6833-741>

⁴ andrej.mushenkov@klgtu.ru ✉

Аннотация. В настоящей работе представлено подробное исследование применения методов машинного обучения для прогнозирования ключевых гидродинамических параметров судов. Актуальность работы обусловлена необходимостью сокращения временных и финансовых затрат на традиционные гидродинамические расчеты при проектировании судов. В исследовании проведен сравнительный анализ трех методов машинного обучения – Linear Regression, Random Forest, Gradient Boosting. Эксперименты выполнены на оригинальном наборе данных, включающем 52 существующих судна классов Feeder и Panamax, с характеристиками «длина», «ширина», «осадка», «скорость», «площадь смоченной поверхности» и «коэффициент общей полноты». Основное внимание уделено прогнозированию чисел Фруда и Рейнольдса для предварительной оценки сопротивления. Результаты демонстрируют превосходство линейной регрессии: для числа Фруда достигнуто $R^2 = 0.9986$ при $MSE = 5.15e-07$, для числа Рейнольдса – $R^2 = 0.9998$ при $MSE = 9.00e+13$. Средняя абсолютная процентная ошибка MAPE (Mean Absolute Percentage Error) составила 0,15 % и 0,57 % соответственно. Итогом является программа расчета на базе искусственного интеллекта (ИИ), которая способна считать значения Fr и Re . Практическая значимость работы обусловлена демонстрацией возможностей новых методов расчета, которые при должном подходе способны повысить точность и оптимизировать процесс классического расчета. Полученные результаты позволяют рекомендовать метод линейной регрессии для предварительной оценки гидродинамических характеристик на ранних этапах проектирования. Практическая значимость работы обусловлена возможностью повышения точности гидродинамических расчетов и оптимизации формы корпуса на основе прогнозируемых данных. Перспективы дальнейших исследований включают расширение набора данных, учет дополнительных параметров и тестирование гибридных моделей.

Ключевые слова: судостроение, искусственный интеллект, машинное обучение, гидродинамика, линейная регрессия, сопротивление судна, число Фруда, число Рейнольдса, прогнозирование.

Для цитирования: Довгополик Д. Д., Гришин П. Р., Великанов Н. Л., Мущенков А. А. Адаптация модели искусственного интеллекта для определения проектных характеристик судна // Известия КГТУ. 2025. № 78. С. 99–114. DOI 10.46845/1997-3071-2025-78-99-114.

Original article

AI Model Adjustment for Determination of Ship Design Characteristics

Denis D. Dovgopolik¹, Pavel R. Grishin², Nikolay L. Velikanov³, Andrey A. Mushenkov⁴✉

^{1,2,3,4.} Kaliningrad State Technical University, Kaliningrad, Russia

¹ AndryshaFF@yandex.ru

² pavel.grishin@klgtu.ru

³ nikolaj.velikanov@klgtu.ru, <http://orcid.org/0000-0001-6833-741>

⁴ andrej.mushenkov@klgtu.ru✉

Abstract. This paper presents a detailed study of machine learning methods application for predicting ships key hydrodynamic parameters. The relevance of the work is due to the need to reduce the time and financial costs of traditional hydrodynamic calculations in ship design. In the study a comparative analysis of three machine learning methods – Linear Regression, Random Forest, Gradient Boosting is carried out. Experiments are performed on an original dataset including 52 existing vessels of Feeder and Panamax classes, with characteristics: length, width, draft, speed, wetted surface area and total completeness ratio. The focus is on predicting Froude and Reynolds numbers for preliminary drag estimation. The results demonstrate the superiority of linear regression: for Froude number, $R^2 = 0.9986$ was achieved at $MSE = 5.15e-07$ and for Reynolds number, $R^2 = 0.9998$ at $MSE = 9.00e+13$. The mean absolute percentage error (MAPE) was 0.15% and 0.57%, respectively. The final result is an AI-based calculation program that is able to read Fr and Re values. The practical significance of the work is due to the demonstration of the possibilities of the new calculation methods, which, with a proper approach, can improve the accuracy and optimize the process of classical calculation. The obtained results allow to recommend the method of linear regression for preliminary assessment of hydrodynamic characteristics at the early stages of design. The practical significance of the work is due to the possibility of improving the accuracy of hydrodynamic calculations and hull shape optimization based on the predicted data. Prospects for further research include expansion of the data set, consideration of additional parameters and testing of hybrid models.

Keywords: shipbuilding, artificial intelligence, machine learning, hydrodynamics, linear regression, ship resistance, Froude number, Reynolds number, prediction.

For citation: Dovgopolik D. D., Grishin P. R., Velikanov N. L., Mushenkov A. A. AI Model Adjustment for Determination of Ship Design Characteristics. *Izvestiya KGTU = KSTU News*. 2025;(78):99–114. (In Russ.). DOI 10.46845/1997-3071-2025-78-99-114.

ВВЕДЕНИЕ

Оценка сопротивления судна является критически важной задачей на этапе проектирования, определяющей энергоэффективность и эксплуатационные характеристики судна. Традиционные методы требуют значительных вычислительных ресурсов и времени, что делает актуальной разработку альтернативных подходов, способных повысить скорость обработки данных. Одним из перспективных направлений в этом контексте является внедрение методов машинного обучения и ИИ, которые позволяют автоматизировать процесс анализа и прогнозирования [1–4].

Традиционные подходы к прогнозированию гидродинамических параметров, такие как интерполяция табличных данных или численное моделирование, обеспечивают приемлемую точность только на известных точках и не всегда способны учитывать сложные нелинейные зависимости [5]. В то же время, применение методов машинного обучения позволяет выявлять скрытые закономерности даже при наличии шума и неопределенностей, что особенно важно при решении задач проектирования морских объектов [6–10]. Такие преимущества были подчеркнуты в работах Marrone S. [9] и Scamardella A. [10], рассматривающих ограничения классических методов и перспективы применения ИИ в области гидродинамики.

Особое внимание следует уделить недавним публикациям, освещающим возможности использования машинного обучения в корабельном проектировании. В частности, в статье Чуреева Е. А. и Пинчука В. И., опубликованной в 2024 г. в сетевом научном издании «Вестник молодежной науки» [11], представлено глубокое изучение вопроса применения ИИ для определения остаточного сопротивления корпуса судна на ранних этапах проектирования. Эти исследования подтверждают актуальность и перспективность такого подхода, особенно при работе с параметрическими моделями и предварительными оценками.

Однако возникает закономерный вопрос: целесообразно ли применять методы ИИ для расчета величин, таких как число Фруда ($Fr = gLv$) и число Рейнольдса ($Re = \mu \rho vL$), которые аналитически определяются через четко заданные физические формулы? В данной работе это обосновывается необходимостью построения комплексного подхода к оценке сопротивления судна, где ИИ используется не вместо точных формул, а как инструмент для оперативного получения входных параметров (скорости, длины, вязкости и др.) на основе ограниченного набора исходных данных проекта. Таким образом, модель ИИ применяется как элемент автоматизации и упрощения подготовки исходных данных, особенно на стадии предварительного проектирования [7].

Кроме того, в работе использовались данные, собранные из открытых источников, в том числе онлайн-платформы, предоставляющие информацию о суд-

не и его технических характеристиках. К ним относятся такие ресурсы, как MarineTraffic [12], My Ship Tracking [13], VesselFinder [14], Equasis [15] и мобильное приложение Ship.info [16]. Эти платформы позволили получить достоверные данные о геометрических параметрах, водоизмещении, скорости хода и других характеристиках судов типов Feeder и Panamax, что обеспечило репрезентативность выборки для последующего обучения моделей машинного обучения.

Собранный набор данных включал следующие входные параметры: длину судна между перпендикулярами (LBP), ширину (B), осадку (T), водоизмещение (∇), скорость хода (V), плотность воды (ρ) и ее кинематическую вязкость (ν). На их основе были рассчитаны числа Фруда и Рейнольдса, а также проведено сравнение результатов, полученных с помощью традиционных методов и предложенной модели машинного обучения.

При реализации модели машинного обучения были протестированы различные алгоритмы, включая линейную регрессию, случайный лес (Random Forest) [2] и градиентный бустинг (Gradient Boosting) [3]. Сравнение производилось на основе метрик RMSE и R . Также планируется переход к анализу средней абсолютной процентной ошибки MAPE для более объективной оценки качества предсказания.

Основной целью работы является адаптация моделей машинного обучения для расчета ключевых гидродинамических параметров, таких как числа Фруда и Рейнольдса, на примере судов типов Feeder и Panamax. Для достижения этой цели были выполнены следующие задачи: во-первых, собран и подготовлен набор данных, включающий геометрические параметры судов, условия эксплуатации и соответствующие значения сопротивления; во-вторых, реализованы и протестированы методы машинного обучения, такие как Linear Regression, Random Forest, Gradient Boosting; в-третьих, проведен сравнительный анализ производительности этих методов на основе метрик RMSE и R выбором наиболее эффективного; в-четвертых, результаты, полученные с выбранной моделью, были сопоставлены с результатами традиционных методов; и, наконец, была проведена оценка применимости, точности и эффективности разработанного подхода, а также определены ограничения исследования и намечены направления для дальнейших исследований.

Использование ИИ для определения величин, которые имеют нелинейную зависимость, имеет большой потенциал, так как правильно обученный под конкретную задачу ИИ способен предсказать все возможные значения конкретной величины при различных условиях. Как отмечал В. С. Чувиковский в своей работе [1], «численный алгоритм следует проектировать так, чтобы процесс его реализации моделировал изучаемый объект, исходная информация которого, вносимая в алгоритм, должна отражать причины и условия существования искомого объекта, а внешние и внутренние погрешности конкретной реализации быть такими, чтобы их можно было рассматривать как разброс в условиях идентификации объ-

екта. Повторяя несколько раз реализацию численного алгоритма, сознательно варьируя в заданных пределах его значения, мы получим совокупность таких объектов. В результате численные расчеты будут являться не приближенными, а существенно более точными и достоверными, чем точное механическое решение исходной задачи».

Иными словами, ключевое преимущество численных методов – в их способности через многократные вариации параметров не просто аппроксимировать и интерполировать данные, а полноценно моделировать физическую сущность явления как такового, при любых разных значениях запоминая результат как некий «опыт».

ОСНОВНАЯ ЧАСТЬ

Данная работа сосредоточена на предсказании чисел Фруда и Рейнольдса с помощью разных способов обучения ИИ. Хотя это не дает непосредственного значения полного сопротивления, тем не менее предсказание этих чисел является важным шагом к более точному и эффективному определению сопротивления судна и позволит в дальнейшем улучшить модели расчета полного сопротивления судна за счет скорости и точности обработки большого объема данных.

Число Рейнольдса (Re) характеризует отношение инерционных сил к силам вязкости и вычисляется по формуле (1):

$$Re = (\rho VL)/\mu, \quad (1)$$

где ρ – плотность воды, V – скорость судна, L – характерный линейный размер (обычно длина), μ – динамическая вязкость воды.

Число Фруда (Fr) характеризует отношение инерционных сил к силам плавучести, определяя величину волнового сопротивления, и вычисляется по формуле (2):

$$Fr = V/\sqrt{(gL)}, \quad (2)$$

где V – скорость судна, g – ускорение свободного падения, L – характерный линейный размер (обычно длина).

Для проведения машинного обучения используется набор данных, состоящий из 52 примеров судов, относящихся к классам Feeder и Panamax. Этот набор данных содержит различные параметры, характеризующие геометрию судов (длина общая и по ватерлинии, ширина, осадка, площадь смоченной поверхности) и их рабочие условия (скорость, глубина воды, коэффициент общей полноты). Такое разнообразие параметров, которых больше, чем надо для определения чисел Фруда и Рейнольдса, обусловлено тем, что в дальнейшем этот же файл будет ис-

пользован и для обучения иных моделей, которые будут заняты расчетом других параметров. Разные «классы» судов обусловлены «практичностью», ведь разнообразие данных снизит возможность появления в будущем такого эффекта, как «переобучение» моделей.

Сами данные представлены в виде электронной таблицы Excel (табл. 1) и применяются для обучения алгоритмов ИИ с целью прогнозирования чисел Фруда и Рейнольдса. Эти параметры будут непосредственно применяться в процессе обучения, что делает такой набор данных ключевым элементом исследования.

Сбор данных о судах был одной из главных задач «предварительного этапа». Было принято решение обратиться к открытым базам данных в сети интернет – сайтам-трекерам судов по типу MarineTraffic [12], MyShipTracking [13] и VesselFinder [14], затем – к конкретным базам данных, таких как сайт Equasis [15] и приложение Ship.info infoship.xyz [16].

В данном исследовании для прогнозирования чисел Фруда и Рейнольдса были использованы три распространенных метода работы ИИ – Linear Regression (линейная регрессия), Random Forest (случайный лес), Gradient Boosting (градиентный бустинг). Каждый из этих методов имеет свои особенности, преимущества и недостатки, что дает повод для экспериментального анализа их применения. Сравнительный анализ результатов всех трех моделей позволит определить наиболее подходящий метод для прогнозирования чисел Фруда и Рейнольдса на основе имеющегося набора данных. Выбор наилучшей модели будет основан на тщательной оценке точности и других соответствующих метрик.

Математически модель линейной регрессии можно представить в виде формулы (3):

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n, \quad (3)$$

где y – прогнозируемое значение (число Фруда или Рейнольдса), b_0 – свободный член (смещение), $b_1, b_2, \dots, b_n$ – коэффициенты регрессии, $x_1, x_2, \dots, x_n$ – входные признаки (параметры судна).

Обучение модели линейной регрессии сводится к подбору коэффициентов $b_0, b_1, b_2, \dots, b_n$, которые минимизируют ошибку между предсказанными и фактическими значениями целевой переменной.

В качестве преимуществ можно отметить простоту реализации и интерпретации результатов, быстрое обучение и предсказание.

Как недостаток следует отметить, что способ предполагает линейную зависимость между признаками и целевой переменной, что может не всегда выполняться в реальных данных (чувствительность к выбросам).

Таблица 1. Данные для обучения модели
Table 1. Data for model training

№	Length	breadth	Draf...	length O.	speed	Wetted	water depth	block coef.	Disp.	L\B	B/T
1	2	3	4	5	6	7	8	9	10	11	12
1	180	28	8	153	12	490,5865	50	0,62004	25000	6,428571	3,5
2	175	27	8	148,75	12	475,0083	50	0,740741	28000	6,481481	3,375
3	185	29	8,5	157,25	12,5	521,7346	50	0,657859	30000	6,37931	3,411765
4	160	26	7,5	136	11	431,5515	50	0,705128	22000	6,153846	3,466667
5	170	27	8	144,5	11,5	468,1733	50	0,680828	25000	6,296296	3,375
6	190	30	9	161,5	13	553,3679	50	0,643275	33000	6,333333	3,333333
7	280	34	10,5	238	13	772,4466	75	0,55022	55000	8,235294	3,238095
8	270	34	10	229,5	13,5	740,247	75	0,631808	58000	7,941176	3,4
9	265	32	10	225,25	13	729,0342	75	0,648585	55000	8,28125	3,2
10	285	35	11	242,25	14	809,2974	75	0,565049	62000	8,142857	3,181818
11	275	33	10,5	233,75	13,5	754,177	75	0,629673	60000	8,333333	3,142857
12	272	33,5	11	231,2	14	773,4968	75	0,568681	57000	8,119403	3,045455
13	278	34	10,8	236,3	13,4	780,6009	75	0,577969	59000	8,176471	3,148148
14	270	32,5	10,6	229,5	13,2	745,1296	75	0,591302	55000	8,307692	3,066038
15	275	33,5	10,9	233,75	13,1	774,2074	75	0,577596	58000	8,208955	3,073394
16	266	32	10,4	226,1	12,9	726,922	75	0,598702	53000	8,3125	3,076923
17	280	34,8	11,1	238	13,6	803,4992	75	0,563988	61000	8,045977	3,135135
18	286	35	11,3	243,1	13,7	821,6968	75	0,556965	63000	8,171429	3,097345
19	276	33,5	10,7	234,6	13,1	768,4651	75	0,596368	59000	8,238806	3,130841
20	269	32,3	10,3	228,65	12,7	730,8889	75	0,603395	54000	8,328173	3,135922
21	270	33	10,5	229,5	12,9	747,2894	75	0,587889	55000	8,181818	3,142857
22	274	34	10,9	232,9	13,2	778,5443	75	0,571179	58000	8,058824	3,119266
23	175	27	8	148,75	12	475,0083	50	0,740741	28000	6,481481	3,375
24	185	29	8,5	157,25	12,5	521,7346	50	0,657859	30000	6,37931	3,411765
25	160	26	7,5	136	11	431,5515	50	0,705128	22000	6,153846	3,466667
26	170	27	8	144,5	11,5	468,1733	50	0,680828	25000	6,296296	3,375
27	190	30	9	161,5	13	553,368	50	0,643275	33000	6,333333	3,333333

Продолжение таблицы 1

1	2	3	4	5	6	7	8	9	10	11	12
28	165	27	7,8	140,25	11,5	455,4351	50	0,690667	24000	6,111111	3,461538
29	170	28	8,2	144,5	12	482,6872	50	0,66612	26000	6,071429	3,414634
30	160	25	7,4	136	11	420,3405	50	0,810811	24000	6,4	3,378378
31	178	29	8,5	151,3	12,3	511,7688	50	0,660939	29000	6,137931	3,411765
32	155	24	7,2	131,75	10,8	399,8463	50	0,746714	20000	6,458333	3,333333
33	182	30	8,8	154,7	12,5	535,5413	50	0,645188	31000	6,066667	3,409091
34	180	28	8,3	153	12,1	499,7003	50	0,693249	29000	6,428571	3,373494
35	165	21	7,3	140,25	11,3	388,5692	50	0,83022	21000	7,857143	2,876712
36	172	27,5	8,1	146,2	12,4	478,2208	50	0,704722	27000	6,254545	3,395062
37	171	27,2	8	145,35	11,9	471,2842	50	0,644995	24000	6,286765	3,4
38	184	29,5	12,6	156,4	12,6	638,9407	50	0,453264	31000	6,237288	2,34127
39	167	29,5	7,8	141,95	11,6	478,9298	50	0,598542	23000	5,661017	3,782051
40	177	28,5	8,2	150,45	12,1	496,9027	50	0,676902	28000	6,210526	3,47561
41	173	27	8,1	147,05	11,8	475,2288	50	0,660762	25000	6,407407	3,333333
42	166	26,3	7,5	141,1	11,2	442,0973	50	0,671889	22000	6,311787	3,506667
43	274	33,5	10,7	232,9	13,1	765,6758	75	0,590539	58000	8,179104	3,130841
44	281	34,7	11,1	238,85	13,6	803,7754	75	0,5636	61000	8,097983	3,126126
45	268	32,5	10,4	227,8	12,8	735,328	75	0,596132	54000	8,246154	3,125
46	277	33,8	10,8	235,45	13,4	776,9006	75	0,583488	59000	8,195266	3,12963
47	270	33	10,6	229,5	13	750,8395	75	0,592931	56000	8,181818	3,113208
48	280	34,5	11	238	13,5	796,4165	75	0,564653	60000	8,115942	3,136364
49	269	32,9	10,5	228,65	12,9	744,7733	75	0,591868	55000	8,176292	3,133333
50	284	35	11,2	241,4	13,7	815,1876	75	0,556913	62000	8,114286	3,125
51	275	33,3	10,8	233,75	13,2	768,344	75	0,586445	58000	8,258258	3,083333
52	287	35,2	11,3	243,95	13,9	825,4805	75	0,551871	63000	8,153409	3,115044

Единственным исследованием в области применения ИИ в судостроении по части определения сопротивления судна является статья «Artificial Neural Network-Based Prediction of Ship Resistance in Shallow Water Conditions», посвященная прогнозированию полного сопротивления в условиях мелководья. Авторы успешно продемонстрировали способность нейронных сетей моделировать сложные нелинейные зависимости между геометрическими характеристиками судна, параметрами мелководья и величиной сопротивления, используя комплексный подход, однако данная тема требует многостороннего подхода и разных методов расчета.

В отличие от приведенного выше исследования, данная работа отличается как по используемым методам, так и по целевым переменным. Результат статьи больше посвящен прямому прогнозированию полного сопротивления, фокусируясь на предсказании чисел Фруда и Рейнольдса – фундаментальных безразмерных параметрах, характеризующих гидродинамические свойства судна. Таким образом, исследование дополняет уже существующие работы, предоставляя сравнительный анализ различных алгоритмов и методов для прогнозирования ключевых гидродинамических параметров, создавая основу для более точного расчета полного сопротивления судов в будущем.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Число Фруда: сравнение, вычисленное против предсказанного числа Фруда (рис. 1), демонстрирует высокую корреляцию между предсказанными и расчетными значениями числа Фруда, что свидетельствует о хорошей точности предсказаний.

Число Рейнольдса: сравнение, вычисленное против предсказанного числа Рейнольдса (рис. 2), показывает высокую степень соответствия между предсказанными и расчетными значениями числа Рейнольдса, что также говорит о высокой точности прогнозирования.

В целом, результаты применения линейной регрессии демонстрируют высокую точность предсказания чисел Фруда и Рейнольдса. Для коэффициента полного сопротивления, хотя значение MSE достаточно большое, показатель R^2 демонстрирует очень высокое качество модели. Несоответствие значений MSE и R^2 для переменных «ct_calculated» и «reynolds» можно объяснить различиями в масштабе этих величин. При этом надо отметить результат MAPE – средний абсолютный процент ошибки, который отражает, насколько в среднем отклоняются предсказанные значения от реальных (рис. 3), это еще одна из метрик, используемых для оценки точности моделей прогнозирования.




Рис. 1. Сравнение, вычисленное против предсказанного числа Фруда
Fig. 1. Comparison calculated against the predicted Froude number




Рис. 2. Сравнение, вычисленное против предсказанного числа Рейнольдса
Fig. 2. Comparison calculated against the predicted Reynolds number

Mean Absolute Percentage Error for Froude: 0.15%
Mean Absolute Percentage Error for Reynolds: 0.57%

Рис. 3. MAPE «Средний абсолютный процент ошибки»

Fig. 3. MAPE "Mean Absolute Percentage of Error"

Средний абсолютный процент ошибки для числа Фруда составляет 0,15 %, а для числа Рейнольдса – 0,57 %. Это означает, что в среднем предсказания модели отклоняются от реальных значений на 0,15 % и 0,57 % соответственно. Обе ошибки являются очень низкими, что говорит о высокой точности предсказания. Модель особенно хорошо прогнозирует число Фруда, а предсказание числа Рейнольдса имеет незначительную погрешность, оставаясь в пределах очень хорошего результата, что подтверждается на рис. 4.

Сравнение предсказанных и расчетных значений (первые 10 строк):

	froude	predicted_froude	reynolds	predicted_reynolds
0	0.318259	0.318713	1.831605e+09	1.842249e+09
1	0.301154	0.301377	1.394000e+09	1.373851e+09
2	0.305442	0.306018	1.548449e+09	1.543535e+09
3	0.326605	0.326786	1.956352e+09	1.972813e+09
4	0.269042	0.267797	2.883045e+09	2.893924e+09
5	0.284517	0.285457	2.887006e+09	2.858168e+09
6	0.276552	0.277640	2.728597e+09	2.794017e+09
7	0.287185	0.287151	3.160261e+09	3.124616e+09
8	0.281918	0.281870	2.940469e+09	2.913282e+09
9	0.293968	0.295353	3.016109e+09	2.982966e+09

Рис. 4. Результат сравнения предсказанных и расчетных значений
в исходном виде

Fig. 4. Result of comparison of predicted and calculated values in the original form

Отдельно обратим внимание на архитектуру итоговой формы ИИ, обученного методом линейной регрессии (рис. 5).




Рис. 5. Блок-схема архитектуры кода
Fig. 5. Block diagram of the code architecture

Код анализирует характеристики судов и с помощью линейной регрессии, предсказывает числа Рейнольдса (Re) и число Фруда (Fr).

Резюмируем этапы выполненной работы.

Загрузка данных. На данном этапе код считывает данные из заранее подготовленного Excel-файла с помощью библиотеки `pandas`. Затем происходит первичная обработка данных:

1. Добавление данных о «классе».
2. Удаление неиспользуемых столбцов данных.

Расчет целевых переменных. Производится механический расчет целевых переменных:

1. Число Фруда (*froude*).
2. Число Рейнольдса (*reynolds*).

Разделение данных на обучающую и тестовую выборки. Для разделения данных используется функция `train_test_split` из библиотеки `sklearn.model_selection`. Разделение данных на тренировочную и тестовую выборки необходимо:

1. Для оценки реальной способности модели к обобщению, поскольку, если обучать модель на одних и тех же данных, она просто придет к «переобучению» и будет плохо работать с новыми данными (в нашем случае идет следующая пропорция: 42 судна для обучения модели, 10 судов для тестирования);

2. Для контроля переобучения. Этот момент необходимо выделить отдельным пунктом и учитывать при обучении модели ИИ. Если модель слишком сильно подстраивается на тренировочные данные (в том числе их шумы), она теряет способность к обобщению. Это легко проверить, когда модель ИИ показывает высокую точность на тренировочной выборке данных, но при работе с тестовыми – результат сильно отличается;

3. Для расчета объективных метрик качества модели, таких как MSE, R^2 и MAPE.

Построение и обучение моделей линейной регрессии. Для каждой целевой переменной создается отдельная модель линейной регрессии с использованием класса `LinearRegression` из библиотеки `sklearn.linear_model`. Обучение проводится методом `fit` на обучающих данных.

Использование одной модели для всех переменных неэффективно, так как числа Фруда и Рейнольдса имеют разную природу и зависимости от признаков. Многозадачная регрессия в данном случае лишь снизит точность прогнозирования.

Оценка качества модели. Для проверки качества моделей на тестовой выборке применяются метрики:

1. `mean_squared_error (MSE)` – среднеквадратичная ошибка, определяет точность предсказаний.
2. `r2_score ( $R^2$ )` – коэффициент детерминации, показывает долю дисперсии, объясняемую моделью.

Визуализация результатов. Для наглядного сравнения предсказанных и реальных значений строятся графики рассеивания с помощью библиотеки *matplotlib*.

ВЫВОДЫ

Данное исследование успешно продемонстрировало возможность использования методов машинного обучения на основе ограниченного набора данных для прогнозирования чисел Фруда и Рейнольдса, которые являются ключевыми гидродинамическими параметрами при расчете судна. Анализ результатов, полученных с применением таких алгоритмов, как линейная регрессия, случайный лес и градиентный бустинг, показал хорошую точность предсказания чисел Фруда и Рейнольдса. Линейная регрессия продемонстрировала высокое значение коэффициента детерминации (R^2), что указывает на хорошее качество модели. Визуализация результатов подтвердила наличие высокой корреляции между предсказанными и расчетными значениями. Полученные результаты свидетельствуют о перспективности использования данного метода для ускорения и оптимизации работы с данными в судостроении.

Полученные результаты открывают новые перспективы для практического применения машинного обучения в судостроении. Как отмечал в своей работе Molland A. F. (2008), «оптимизация гидродинамических параметров на ранних этапах проектирования критически важна для экономии ресурсов» [8]. Наше исследование подтверждает, что машинное обучение, особенно линейная регрессия, может стать инструментом для этой самой оптимизации. Разработанные модели могут быть использованы на этапе предварительной оценки сопротивления судов, что оптимизирует процесс проектирования за счет ускорения анализа и расчета большего массива данных, а также повышает точность и надежность проектных решений.

Важно отметить, что ИИ не сможет полноценно заменить инженера – он лишь расширит пространство для возможных решений, которые специалист сможет осмысленно выбрать.

Список источников

1. Чувиковский, В. С. Численные методы расчетов в строительной механике корабля / В. С. Чувиковский. – Ленинград: Судостроение, 1976. – 374 с.
2. Breiman, L. Random forests / L. Breiman. – DOI: 10.1023/A:1010933404324// Machine learning. – 2001. – V. 45. N 1. – P. 5–32. URL: <https://doi.org/10.1023/A:1010933404324> (дата обращения: 05.03.25).
3. Friedman, J. H. Greedy function approximation: A gradient boosting machine/ J. H. Friedman. – Annals of statistics, 2001. – P. 1189–1232.

4. Ghassemi, H. Artificial Neural Network-Based Prediction of Ship Resistance in Shallow Water Conditions / H. Ghassemi, P. Ghadimi, M. Daryabor. – DOI: 10.1016/j.oceaneng.2023.115053 // Ocean Engineering. – 2023. – V. 281. 115053. URL: <https://doi.org/10.1016/j.oceaneng.2023.115053> (дата обращения: 05.03.25).
5. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. / T. Hastie, R. Tibshirani, J. H. Friedman, J. Franklin. – 2nd ed. – N. Y.: Springer, 2009. – 745 p.
6. Recommended Procedures and Guidelines: Uncertainty Analysis in CFD Verification and Validation Methodology and Procedures / K. Maki, F. Zhao, P. Horn [et al.]. – DOI: 7.5-02-02-01 // Switzerland: ITTC. – 2017. – P. 1–15. URL: <https://www.ittc.info/media/11950/75-03-01-01.pdf> (дата обращения: 05.03.25).
7. Larsson, L. Principles of Naval Architecture. Resistance, Propulsion and Vibration / L. Larsson, H. Raven. – Jersey City: SNAME, 2010. – V. II. – 418 p.
8. Molland, A. F. The Maritime Engineering Reference Book. / A. F. Molland. – Oxford: Butterworth-Heinemann, 2008. – 928 p.
9. Marrone, S. Resistance prediction of high speed planing hull using multiple regression approach / S. Marrone, D. Peri, A. Scamardella. – DOI: 10.1016/j.oceaneng.2017.02.015 // Ocean Engineering. – 2017. – V. 135. – P. 1–8. URL: <https://doi.org/10.1016/j.oceaneng.2017.02.015> (дата обращения: 05.03.25).
10. Scamardella, A. Machine learning for the prediction of ship resistance of fast vessels: A comparative analysis / A. Scamardella. – DOI: 10.1016/j.oceaneng.2021.109877 // Ocean Engineering. – 2021. – V. 240. URL: <https://doi.org/10.1016/j.oceaneng.2021.109877> (дата обращения: 05.03.25).
11. Чуреев, Е. А. Возможность использования машинного обучения для определения остаточного сопротивления корпуса судна на ранних этапах проектирования / Е. А. Чуреев, В. И. Пинчук. – DOI: 10.46845/2541-8254-2024-1(43)-16-16 // Вестник молодежной науки. – 2024. – № 1 (43). – С. 10. URL: [https://doi.org/10.46845/2541-8254-2024-1\(43\)-16-16](https://doi.org/10.46845/2541-8254-2024-1(43)-16-16) (дата обращения: 07.07.25).
12. Marine Traffic: Global Ship Tracking Intelligence – AIS Marine Traffic: сайт. – URL: <https://www.marinetraffic.com> (дата обращения: 05.03.25).
13. My Ship Tracking Free Realtime AIS – Vessel Trackin. Vessels Finder: сайт. – URL: <https://www.myshiptracking.com> (дата обращения: 05.03.25).
14. Ship & Container Tracking – VesselFinder: сайт. – URL: <https://www.vesselfinder.com> (дата обращения: 05.03.25).
15. Equasis – European Quality Shipping Information System: сайт. – URL: <https://www.equasis.org> (дата обращения: 05.03.25).
16. Ship.info – Мобильное приложение. – URL: <https://infoship.xyz/> (дата обращения: 05.03.25).

References

1. CHuvikovskiy V. S. *CHislennyye metody raschetov v stroitel'noy mekhanike korablya* [Numerical methods of calculations in ship construction mechanics]. Lenin-grad, Sudostroenie Publ., 1976. 374 p.
2. Breiman L. Random forests. DOI: 10.1023/A:1010933404324. Machine learning. 2001. V. 45. N. 1. P. 5–32. Available at: <https://doi.org/10.1023/A:1010933404324> (accessed 5 March 2025).
3. Friedman J. H. Greedy function approximation: A gradient boosting machine. *Annals of statistics*. 2001. P. 1189–1232.
4. Ghassemi H. Artificial Neural Network-Based Prediction of Ship Resistance in Shallow Water Conditions. DOI: 10.1016/j.oceaneng.2023.115053. *Ocean Engineering*. 2023. V. 281. 115053. Available at: <https://doi.org/10.1016/j.oceaneng.2023.115053> (accessed 05 March 2025).
5. Hastie T., Tibshirani R., Friedman J. H., Franklin J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed. N. Y., Springer. 2009. 745 p.
6. Maki K., Zhao F., Horn P. [et al.]. Recommended Procedures and Guidelines: Uncertainty Analysis in CFD Verification and Validation Methodology and Procedures. DOI: 7.5-02-02-01. Switzerland, ITTC. 2017. P. 1–15. Available at: <https://www.ittc.info/media/11950/75-03-01-01.pdf> (accessed 05 March 2025).
7. Larsson L., Raven H. *Principles of Naval Architecture. Resistance, Propulsion and Vibration*. Jersey City, SNAME. 2010. V. II. 418 p.
8. Molland A. F. *The Maritime Engineering Reference Book*. Oxford, Butterworth-Heinemann, 2008. 928 p.
9. Marrone S., Peri D., Scamardella A. Resistance prediction of high speed planing hull using multiple regression approach. DOI: 10.1016/j.oceaneng.2017.02.015. *Ocean Engineering*. 2017. V. 135. P. 1–8. Available at: <https://doi.org/10.1016/j.oceaneng.2017.02.015> (accessed 05 March 2025).
10. Scamardella A. Machine learning for the prediction of ship resistance of fast vessels: A comparative analysis. DOI: 10.1016/j.oceaneng.2021.109877. *Ocean Engineering*. 2021. V. 240. Available at: <https://doi.org/10.1016/j.oceaneng.2021.109877> (accessed 05 March 2025).
11. CHureev E. A. Vozmozhnost' ispol'zovaniya mashinnogo obucheniya dlya opredeleniya ostatochnogo soprotivleniya korpusa sudna na rannikh etapakh proektirovaniya [Possibility of using machine learning to determine the residual resistance of the ship hull at the early stages of design]. DOI: 10.46845/2541-8254-2024-1(43)-16-16. *Vestnik molodezhnoy nauki*. 2024, no. 1 (43), p. 10. Available at: [https://doi.org/10.46845/2541-8254-2024-1\(43\)-16-16](https://doi.org/10.46845/2541-8254-2024-1(43)-16-16) (accessed 05 March 2025).
12. Marine Traffic: Global Ship Tracking Intelligence – AIS Marine Traffic: sayt [website]. Available at: <https://www.marinetraffic.com> (accessed 05.03.25).

13. My Ship Tracking Free Realtime AIS – Vessel Trackin. Vessels Finder: sayt [website]. Available at: <https://www.myshiptracking.com> (accessed 05 March 2025).

14. Ship & Container Tracking – VesselFinder: sayt [website]. Available at: <https://www.vesselfinder.com> (accessed 05 March 2025).

15. Equasis – European Quality Shipping Information System: sayt [website]. Available at: <https://www.equasis.org> (accessed 05 March 2025).

16. Ship.info. Mobil'noe prilozhenie [Mobile app]. Available at: <https://infoship.xyz/> (accessed 05 March 2025).

Информация об авторах

Д. Д. Довгополик – бакалавр 4-го курса Научно-образовательного центра судостроения, морской инфраструктуры и техники

П. Р. Гришин – старший преподаватель Научно-образовательного центра судостроения, морской инфраструктуры и техники

Н. Л. Великанов – доктор технических наук, профессор, профессор Научно-образовательного центра судостроения, морской инфраструктуры и техники

А. А. Мушенков – аспирант 1-го года обучения Научно-образовательного центра судостроения, морской инфраструктуры и техники

Information about the authors

D. D. Dovgopolik - 4th year Bachelor of Science and Education Center of Shipbuilding, Marine Infrastructure and Engineering

P. R. Grishin - senior lecturer of the Scientific and Educational Center of Shipbuilding, Marine Infrastructure and Engineering

N. L. Velikanov - Doctor of Technical Sciences, Professor, Professor of the Scientific-Educational Center of Shipbuilding, Marine Infrastructure and Engineering

A. A. Mushenkov - 1st year postgraduate student of the Scientific-Educational Center of Shipbuilding, Marine Infrastructure and Engineering

Статья поступила в редакцию 06.07.2025; одобрена после рецензирования 16.07.2025; принята к публикации 17.07.2025.

The article was submitted 06.07.2025; approved after reviewing 16.07.2025; accepted for publication 17.07.2025.