

Известия Балтийской государственной академии
рыбопромыслового флота. 2026. № 3(77). С. 157–161

Научная статья

УДК 377.1:627.717

Doi:10.46845/2071-5331-2026-3-77-157-161

Технологии глубокого обучения для прогнозирования маршрутов движения судов

Павел Юрьевич Ковалишин¹, Марина Васильевна Бураковская²

^{1,2}Балтийская государственная академия рыбопромыслового флота ФГБОУ ВО «КГТУ»,
Калининград, Россия

¹pavelkovalishinkaliningrad@mail.ru; <https://orcid.org/0000-0002-1092-1474>

²bgarf1988@inbox.ru; <https://orcid.org/0000-0002-0179-2332>

Аннотация. Рассматриваются механизмы использования глубокого обучения для прогнозирования маршрутов движения судов. Интенсивность морского трафика стремительно растет: эффективное прогнозирование является одной из важнейших задач интеллектуальной транспортной системы. Глубокое обучение (Deep Learning, DL) – это подраздел машинного обучения, в котором используются многослойные искусственные нейронные сети для автоматического выявления сложных закономерностей в больших данных. В отличие от классического машинного обучения, DL-модели самостоятельно извлекают признаки (feature learning) без участия человека, что позволяет достигать высокой точности в компьютерном зрении, распознавании речи и генеративном ИИ. Глубокое обучение позволяет вычислительным моделям, состоящим из нескольких обрабатывающих слоев, изучать представления данных с несколькими уровнями абстракции.

Ключевые слова: прогнозирование трафика, глубокое обучение, нейронные сети, вычислительные модели

Для цитирования Ковалишин, П. Ю., Бураковская, М. В. Технологии глубокого обучения для прогнозирования маршрутов движения судов // Известия Балтийской государственной академии рыбопромыслового флота. – 2026. – № 3(77). – С. 157–161.

Введение

Прогнозирование движения судов – одна из наиболее трудоемких задач в сфере интеллектуальных морских систем, требующая учета множества переменных. Наличие актуальных данных о трафике выгодно как администрациям портов, так и судовладельцам, поскольку оно:

- способствует рациональному планированию работы терминалов;
- снижает плотность транспортных заторов и объем выбросов парниковых газов;
- повышает уровень общей безопасности мореплавания;
- помогает судам оптимизировать навигацию, исключать риски столкновений и избегать неоправданных расходов из-за задержек.




Рис. 1. Входящий и исходящий потоки судов



Развитие методов прогнозирования морского трафика прошло путь от классических статистических подходов до современных архитектур глубокого обучения

1. Традиционные методы и гибридные подходы. Ранние исследования были сосредоточены на адаптации классических алгоритмов машинного обучения. Так, Li et al. [1] предложили гибридный метод на основе робастной регрессии опорных векторов (RSVR), а He et al. [2] адаптировали фильтр Калмана для задач краткосрочного прогнозирования. Особое внимание уделялось оптимизации обучения: Wang et al. [3] использовали нейронные сети обратного распространения (BP) с анализом остатков, а Yang et al. [4] представили улучшенную радиально-базисную сеть (EHRBF-NN), показавшую высокую эффективность в моделировании судовых потоков.




Рис. 2. Модель сверточной нейронной сети (CNN)

2. Глубокое обучение и временные последовательности

С ростом объема данных АИС (AIS) акцент сместился на рекуррентные архитектуры. Chen et al. [5] одними из первых применили многослойную сеть долговременной кратковременной памяти (LSTM) для анализа затонов на реальных навигационных картах. Параллельно с этим в смежных отраслях, таких как дорожный транспорт, Lv et al. [6] и Zhang et al. [7] заложили фундамент использования глубоких пространственно-временных остаточных сетей (ST-ResNet) для анализа крупномасштабных потоков данных.




Рис. 3. Модель LSTM и полная структура модели LSTM

3. Современное состояние (2020–2024 г.): внимание и графы

В последние годы область перешла к использованию механизмов внимания (Attention) и графовых нейронных сетей (GNN), которые лучше учитывают топологию морских путей [8]:

Трансформеры и механизмы внимания: Исследования Li et al. [9] показали, что модели на основе Transformer значительно превосходят LSTM в задачах долгосрочного прогнозирования траекторий, так как они эффективнее улавливают зависимости между маневрами судна на больших временных интервалах.

Графовые нейронные сети (GNN): Поскольку морские пути представляют собой сеть узлов (портов) и ребер (маршрутов), Wang et al. [10] предложили пространственно-временные графовые сверточные сети (ST-GCN). Это позволило моделировать корреляции между плотностью трафика в разных географических зонах одновременно.

Генеративные модели: В 2023–2024 гг. появились работы (например, Zhang et al. [11]), использующие диффузионные модели и GAN для восстановления пропущенных данных АИС и генерации реалистичных сценариев движения в условиях неопределенности.

Ключевые преимущества глубокого обучения (Deep Learning)

Реализация сквозного обучения (End-to-End): Архитектуры глубоких нейронных сетей позволяют обрабатывать неструктурированные входные данные напрямую. Это исключает этап ручного проектирования признаков (feature engineering), обеспечивая автоматическое извлечение релевантных паттернов.

Высокая предиктивная точность: DL-модели демонстрируют значительное превосходство в точности аппроксимации и классификации по сравнению с классическими методами машинного обучения.




Рис. 4. Структура двунаправленной рекуррентной нейронной сети

Универсальность применения: Технология является фундаментальной для прорывных решений в таких областях, как компьютерное зрение (Computer Vision), обработка естественного языка (NLP), интеллектуальные транспортные системы и автономная навигация.

Несмотря на стремительное развитие методов глубокого обучения (DL), основная масса исследований сосредоточена в сегменте наземного транспорта. Данный дисбаланс обусловлен двумя факторами.

Доступность данных: наземные интеллектуальные системы оперируют колоссальными массивами данных, в то время как в морской отрасли сбор и агрегация «больших данных» (Big Data) сопряжены с техническими и коммерческими сложностями.

Степень детерминированности: трафик автомобилей и поездов жестко ограничен инфраструктурой (дорожной сетью), что упрощает выявление закономерностей. В то же время движение судов характеризуется большей степенью свободы и зависимостью от внешних гидрометеорологических условий.



На текущем этапе применение DL в морской навигации ограничено локальными задачами: идентификацией типов судов, реконструкцией траекторий, детекцией аномалий и предотвращением столкновений. При этом прогнозирование совокупных транспортных потоков (маршрутных трафиков) остается малоизученным направлением, требующим разработки специализированных прогностических моделей.

Заключение и выводы

1. Научная и практическая значимость

Прогнозирование судоходных потоков является фундаментальным компонентом развития интеллектуальных морских транспортных систем (IMTS). Получение высокоточных данных о трафике в режиме реального времени критически важно для двухуровневого управления.




Рис. 5. Гибридная модель BDLSTM-CNN

На макроуровне: позволяет береговым службам и администрациям портов оптимизировать логистические процессы.

На микроуровне: обеспечивает экипажи судов информацией для безопасного маневрирования и соблюдения графиков прибытия.

2. Предложенное решение и результаты

В ходе исследования было обосновано преимущество методов глубокого обучения (Deep Learning) перед классическими статистическими моделями. Ключевые результаты работы:

Эффективность архитектуры: применение глубоких нейронных сетей позволило достичь качественно нового уровня точности в прогнозировании маршрутов.

Оптимальная модель: наилучшие показатели продемонстрировала гибридная архитектура BDLSTM-CNN, сочетающая способность двунаправленных рекуррентных сетей (BDLSTM) анализировать временные зависимости и мощность сверточных слоев (CNN) в извлечении пространственных признаков.

3. Направления дальнейших исследований

Несмотря на достигнутые результаты, выделены перспективные векторы развития данной области:

- Обогащение признакового пространства: интеграция в модель внешних факторов, таких как гидрометеорологические условия (погода), динамические параметры кинематики судна и данные о маневрах по расхождению для предотвращения столкновений.

- Масштабирование горизонта прогноза: увеличение количества расчетных точек для формирования долгосрочных прогнозов транспортных потоков.

– Переход к интеллектуальным агентам: апробация методов на базе многоагентных систем (MAS) и обучения с подкреплением (Reinforcement Learning) для моделирования адаптивного поведения судов в сложных навигационных ситуациях.

Список источников

1. Li, M. W., Han, D.F., Wang, W.L. Vessel traffic flow forecasting by RSVR with chaotic cloud simulated annealing genetic algorithm and KPCA // *Neurocomputing*. – 2015. – P. 243–255.
2. He, Y. et al. An improved Kalman filter model for short-term vessel traffic flow prediction // *Journal of Navigation*. – 2017.
3. Wang, Ch., Zhang, X., Chen, X., Li, R., Li, G. Vessel traffic flow forecasting based on BP neural network and residual analysis // *4th International Conference on Information, Cybernetics and Computational Social Systems (ICCSS)*. – 2017. – Pp. 350–354.
4. Yang, L., Hao, Y., Liu, Q., Zhu X. Ship traffic volume forecast in bridge area based on enhanced hybrid radial basis function neural networks // *Proceedings of the International Conference on Transportation Information and Safety (ICTIS)*, Wuhan, China, 25–28. – June 2015. – Pp. 38–43.
5. Chen, L. et al. Stacked LSTM (long short-term memory) network for traffic congestion forecasting on realistic navigation maps // *IEEE Transactions on Intelligent Transportation Systems*. – 2016.
6. Lv, Y., Duan, Y., Kang, W., Li, Z., Wang, F. Y. Traffic flow prediction with big data: A deep learning approach // *IEEE Transactions on Intelligent Transportation Systems*. – 2015. – 16(2). – Pp. 865–873.
7. Zhang, J., Zheng, Y., Qi D. Deep spatio-temporal residual networks for citywide crowd flow prediction // *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI-17)*. – 2017.
8. Zhao, L., & Liu, Y. (2023). Hybrid Deep Learning Models for Real-time Ship Collision Avoidance and Path Planning. *Reliability Engineering & System Safety*, 231. – Pp. 108–124.
9. Li, S. et al. A Transformer-based Framework for Vessel Trajectory Prediction with Attention Mechanisms // *Ocean Engineering*. – 2022. – 244. – Pp. 110–135.
10. Wang, X. et al. Spatiotemporal Graph Convolutional Networks for Vessel Traffic Flow Forecasting in Complex Waterways // *IEEE Transactions on Intelligent Transportation Systems*, 2023. – № 24(8). – Pp. 8567–8582.
11. Zhang, M. et al. Diffusion Models for AIS Data Recovery and Trajectory Generation in Marine Navigation // *Journal of Marine Science and Engineering*. 2024. – № 12(2). – P. 341.

Информация об авторах

П. Ю. Ковалишин – кандидат филологических наук, доцент;
М. В. Бураковская – кандидат технических наук, доцент.

Статья поступила в редакцию 01.07.2026; одобрена после рецензирования 03.08.2026; принята к публикации 10.08.2026.