

УДК 656.61.052
EDN DEGXLP

Н. В. КУЗНЕЦОВ, Б. С. РИВКИН

НЕЙРОННЫЕ СЕТИ В РЕШЕНИИ ЗАДАЧ СУДОВОЖДЕНИЯ

Статья представляет собой обзор технологий нейронных сетей (НС), используемых при решении задач обеспечения плавания морских надводных объектов. Рассматриваются проблемы формирования траекторий движения, вопросы обнаружения, классификации и расхождения со встречными судами, а также комплексирования навигационных данных и устранения киберрисков.

Ключевые слова: искусственный интеллект, навигационная безопасность плавания, нейронная сеть, безэкипажные суда, траектория, обнаружение, осведомленность, классификация, расхождение, комплексирование, кибербезопасность.

Введение

В последние годы наблюдается резко возрастающий интерес к применению методов искусственного интеллекта (ИИ) в задачах навигации. Анализ публикаций в библиографической базе *Scopus (Elsevier)* приводит к следующим результатам¹. По ключевым словам *Navigation & Artificial Intelligence* в этой системе на март 2024 г. имеется более 6370 публикаций. Динамика публикаций в *Scopus* за период 1971–2023 гг. представлена на рис. 1. Заметен резкий (почти экспоненциальный) рост их количества начиная с 1995 г.

Кузнецов Николай Владимирович. Член-корреспондент РАН, заведующий кафедрой, Санкт-Петербургский государственный университет. Действительный член международной общественной организации «Академия навигации и управления движением».

Ривкин Борис Самуилович. Кандидат технических наук, начальник Центра компетенций в области навигации, АО «Концерн «ЦНИИ «Электроприбор» (С.-Петербург). Действительный член международной общественной организации «Академия навигации и управления движением».

¹ https://www.elsevier.com/products/scopus?dgcid=RN_AGCM_Sourced_300005030.




Рис. 1

По различным областям публикации в *Scopus* в основном разделяются следующим образом: *ComputerScience* – 4312, *Engineering* – 2851, *Mathematics* – 1451, *PhysicsandAstronomy* – 623. Результаты применения методов ИИ в задачах навигации представлены в 37 монографиях, 126 главах в сборниках, 243 журнальных обзорах, 1848 журнальных статьях, 278 обзорных и 3803 тематических докладах на конференциях. Все это побудило авторов ознакомить читателей журнала «Гироскопия и навигация» с использованием ИИ в морских приложениях, тем более что на текущий момент на его страницах размещен всего лишь один материал [1], посвященный этой тематике. Под ИИ-методами понимаются машинное и глубокое обучение, о которых речь пойдет далее. В процессе написания статьи выяснилось, что в большинстве случаев в интересующей нас области при этом используются НС-технологии. Последнее и предопределило ее название.

Адепты ИИ полагают [2, 3], что использование его технологий приведет к революции в судовождении, обеспечив в том числе:

- автоматизацию принятия решений, прежде всего при расхождении со встречаемыми судами;
- интегрирование данных навигационных систем на новом уровне;
- минимизацию ошибок вахтенных офицеров;
- прокладку маршрута судна на основе реальных данных, включая погодные условия, морской трафик и потенциальные опасности;
- эффективное использование данных прошлых рейсов;
- прогнозирование отказов аппаратуры.

Уже сегодня множатся примеры внедрения ИИ-процедур в практику морских перевозок [4]. Так, Сингапурский университет управления (Singapore Management University), компания Fujitsu (Япония) и Институт высокопроизводительных вычислений A*STAR (A*STAR Institute of High-Performance Computing, Сингапур) работают над созданием технологий ИИ для управления движением судов в порту Сингапура, а также в Сингапурском и Малаккском проливах – самых загруженных в мире. Японская судоходная компания Mitsui OSK Lines и китайская технологическая компания Sense Time проводят, используя камеры сверхвысокого разрешения и графический процессор, исследования по применению ИИ в системах распознавания изображений судов. Rolls-Royce в сотрудничестве с Intel и Google задействует ИИ для повышения безопасности морских операций, внедрив систему интеллектуальной

осведомленности об окружающей среде Intelligent Awareness. Фирма Orca AI (Израиль) на базе оригинальных оптических датчиков, тепловизионных камер и ИИ создала систему технического зрения беспрецедентного качества, которая была размещена более чем на 1000 морских объектов, и тем самым резко повысила уровень решения задачи ситуационной осведомленности судоводителя в условиях плохой видимости.

Особую роль ИИ, в частности машинное обучение (МО), играет при проектировании безэкипажных судов (БЭС), и прежде всего тех из них, на которых в соответствии с классификацией Международной морской организации [5] экипаж вовсе отсутствует. При этом под МО понимают подраздел ИИ, для решения схожих задач разрабатывающий алгоритмы и модели, способные обучаться на основе больших наборов данных без явного установления конкретных правил или инструкций. Наибольший интерес при этом представляют решения, обеспечивающие плавание БЭС в соответствии с Международными правилами предупреждения столкновения судов в море (Convention on the International Regulations for Preventing Collisions at Sea – COLREGs) и претендующие на уровень безопасности, поддерживаемый обычными участниками движения на море. Вместе с тем роль ИИ применительно к БЭС на текущий момент до конца не определена. Некоторые, например, полагают, что БЭС станет автономным лишь тогда, когда появятся технологии, позволяющие ИИ обучаться в процессе эксплуатации, что неминуемо приведет к проблемам с сертификацией установленного на судне оборудования.

Преимущества и недостатки использования ИИ на БЭС рассмотрены в работе [6]. Важнейшими проблемами, подлежащими, по мнению ее авторов, решению применительно к БЭС, являются обнаружение и классификация внешних объектов и прогнозирование ситуационной обстановки с планированием и реализацией соответствующих действий, например направленных на предупреждение столкновений. Для имплементации этих функций предлагается прежде всего сосредоточиться на создании систем ситуационной осведомленности (ССО) и автономной навигации (САН). Основное требование к ССО в рассматриваемом случае – обеспечить выявление всех опасных участников движения и совместно с САН обеспечить расхождение с ними. При этом допускается, что в отношении БЭС, к тому же эксплуатируемого совместно с обычными судами, соблюсти требования COLREGs в 100% случаев не удастся. Более того, если МО-модель не обеспечивает требуемого качества решения задачи (плохо обучена, не учитывает вновь реализовавшиеся внешние обстоятельства, устаревает в процессе жизненного цикла судна и т.д.), предлагается переходить на дистанционное управление движением судна.

С целью уточнения своей позиции авторы [6] вводят понятия «объяснимого ИИ» (explainable artificial intelligence – AI) и «заслуживающего доверия ИИ» (trustworthy AI). Определение первого из них было дано в 2019 г. Управлением перспективных исследований и разработок министерства обороны США (Defence Advanced Research Projects Agency) в следующем виде: «ИИ – система, способная объяснить человеку-потребителю свое предназначение, свои сильные и слабые стороны и сформировать представление о том, как она будет вести себя в будущем». Очевидно, что технологии «объяснимого ИИ» нацелены на обслуживание интересов потребителя.

«Заслуживающий доверия ИИ» ориентирован прежде всего на оценку неопределенности МО-модели и должен быть способен определить тот момент, когда переход на дистанционное управление судном становится обязательным. В этом случае адек-

ватность модели во всех ситуациях необязательна, но необходимо, чтобы она четко фиксировала пределы возможности ее применения. Тогда по большей части, когда на входе модели будут данные, соответствующие медианным значениям параметров, по которым МО-модель тренировалась, риск ее использования будет минимален и вероятность привлечения оператора для дистанционного управления судном будет также невелика.

Специфика задействования ИИ в судовождении обсуждается и в статье [7], результаты которой не противоречат исследованиям работы [6]. По мнению ее авторов, ИИ может найти применение для решения следующих задач:

- визуального наблюдения за окружающей обстановкой;
- контроля за состоянием судна и груза как единой системы с учетом морских условий, и прежде всего волнения (создание системы типа ССО);
- обеспечения безопасного расхождения судов в районе интенсивного судоходства.

Однако существуют как минимум 2 проблемы применения ИИ в рассматриваемой области. Во-первых, для реализации МО-процедуры требуется наличие репрезентативного и адекватного практике набора данных. Во-вторых, алгоритмы ИИ чрезвычайно сложны для понимания неопитами, и отсутствие представления о том, как они работают, приводит к недоверию технологиям ИИ. По утверждению авторов статьи [7], первоочередной задачей является преодоление второй из указанных проблем, для чего требуется создание механизма для верификации ИИ-алгоритма. Отсутствие объективных показателей качества его работы, при их наличии для большинства традиционно используемых статистических процедур обработки данных, в определенной степени сдерживает развитие и применение ИИ в практике судовождения.

Цель настоящей работы – ознакомить читателя, не имеющего опыта применения ИИ, с НС-процедурами, используемыми в настоящее время при решении типовых задач судовождения. При этом авторы не претендуют ни на полноту охвата рассматриваемой проблемы, ни на глубину погружения в структуру и специфику НС-алгоритмов, равно как и на обзор того, каким образом в настоящий момент обстоят дела с развитием НС-технологий как таковых.

Далее рассматриваются лишь надводные суда, в том числе и БЭС, создание которых без привлечения НС-технологий не представляется возможным. Случай эксплуатации каких-либо подводных объектов не изучается в силу его специфики, требующей специального исследования.

Статья структурирована следующим образом. После введения идут разделы, посвященные:

- движению судна по маршруту;
- обнаружению объектов и их классификации;
- расхождению со встречными судами;
- комплексированию ИНС/ГНСС;
- кибербезопасности и НС.

Завершает статью заключение.

Движение судна по маршруту

В этом разделе внимание будет уделено прогнозу морского трафика и траектории движения судна, а также планированию маршрута.

Прогноз морского трафика

Прогноз морского трафика является одной из наиболее сложных задач в судовождении, особенно если речь идет о БЭС. На его результаты оказывают влияние качество предсказания траектории судна, с одной стороны, и такие явления, как загруженность трассы, общая плотность морского движения, возможность столкновения со встречным судном и т.д., – с другой.

Алгоритм прогноза трафика, предложенный в работе [8], основан на применении НС и предусматривает проведение 6 процедур:

- формирования набора исходных данных о движении судна, получаемых от судовой автоматической идентификационной системы (АИС);
- предварительной их обработки, предполагающей интерполяцию недостающих величин и отбраковку ложных данных (занимает до 80% времени решения задачи);
- учета дополнительных факторов (feature augmentation) в модели решения задачи, повышающих работоспособность НС;
- проектирования модели;
- обучения модели;
- валидации модели с получением результатов.

Учитывая, что данные о морском трафике представляют собой последовательность, характерную для временных рядов, для решения задачи была использована НС типа LSTM (Long Short-Term Memory – длинная цепь с элементами краткосрочной памяти), усовершенствующая НС рекуррентного типа (Recurrent Neural Network – RNN). Она была выбрана из-за способности обрабатывать большие массивы данных и преодолевать проблему «исчезающего градиента», характерную для прогнозирования временных рядов.

Указанная проблема возникает при обучении НС методом обратного распространения ошибки (error backpropagation – BP) [70], который базируется на градиентном спуске и требует вычисления градиентов функции потерь, фиксирующей отличие прогноза модели от истинных данных, по всем обучающим параметрам с соответствующей корректировкой весов модели. Проблема исчезновения градиента имеет место, когда последний уменьшается по мере его вычисления при перемещении по слоям сети в обратном направлении, в силу чего процесс обучения замедляется или, в крайнем случае, прерывается. В частности, это характерно для сетей со многими скрытыми слоями.

Решалась задача входа в порт Ульсан (Южная Корея). Предполагалось, что основные факторы, влияющие на результат, – число судов, способных войти в порт по навигационным ограничениям на фиксированном интервале времени, и общий объем морского трафика при входе в порт на том же интервале. В качестве дополнительных параметров служили изменение нагруженности трафика (которая определялась отношением числа судов, способных войти в порт, к их количеству на входе), вероятность и скорость ее изменения, а также ее среднее и максимальное значение за 3, 6, 9 и 24 дня.

При проверке качества работы алгоритма во всех изучавшихся сценариях объем данных для обучения НС соотносился с объемом данных для ее валидации как 8:2. При изменении этого соотношения на 7:3 в результатах практически ничего не менялось, что свидетельствует о высокой эффективности предложенной процедуры.

За критерий оценки функционирования НС была принята нормированная среднеквадратическая погрешность (СКП) прогноза числа судов на входе в Ульсан. В са-

мом простом эксперименте, когда в расчет принимались только основные факторы, СКП составила 0,27. Когда к ним добавились изменение нагруженности трафика, вероятность и скорость ее изменения, СКП снизилась до 0,22. Наконец, при учете всех дополнительных факторов была получена СКП = 0,084. Из приведенных результатов следует, что с увеличением числа входных данных, по которым обучается и тестируется НС, эффективность решения задачи повышается, что, впрочем, очевидно.

Аналогичной проблемой занимались и авторы статьи [9], привнеся в ее решение свежую идею. Они предложили рассмотреть ситуацию, когда движение судов при входе в порт осуществляется по нескольким галсам и загруженность каждого из них оказывает влияние на трафик в целом. Исходные данные для оценки трафика и в этом случае поступали в соответствующую береговую структуру от аппаратуры АИС, установленной на судах, перемещающихся в изучаемом регионе.

В статье приведен обзор методов прогнозирования трафика на основе представляющего собой подраздел МО глубокого обучения (ГО), при котором используется многослойная НС и при обработке данных имитируется функционирование человеческого мозга, с этой целью применяются слои нейронов для обнаружения иерархических представлений. Анализ этих методов выявил следующие два их недостатка:

- 1) при обучении соответствующих НС не удастся в полной мере учесть изменение во времени, а главное, в пространстве факторов, влияющих на трафик;
- 2) решение задачи с привлечением данных по судам, движущимся по 2-м соседним галсам с высокой степенью сходства в изменениях упомянутых факторов, резко усложняется, когда требуется прогнозировать трафик, принимая во внимание движение по всем галсам.

Для устранения этих недостатков в [9] предлагается новая методология прогнозирования, основанная на трех представлениях информации: пространственном, временном и группировки по сходству. В частности, первые два позволяют парировать первый недостаток, а группировка по сходству – второй.

Изменение пространственных факторов, воздействующих на трафик, анализируется в статье с применением сверточной нейронной сети (Convolutional Neural Network – CNN), а самого трафика с течением времени – LSTM. Идентификация галсов со схожими характеристиками потока движения судов выполнялась на основе метода динамической трансформации временной шкалы (Dynamic Time Warping), позволяющего найти оптимальное соответствие между временными последовательностями [10].

Эффективность итогового алгоритма ICLSGNet исследовалась в регионе порта Шэньчжэнь (провинция Гуандун, Китай), имеющего 8 входных–выходных фарватеров, сопоставлением результатов его применения и оценками 11 других популярных алгоритмов, из которых 5 опирались на НС и 6 – на ГО. В большинстве случаев СКП прогноза потока движения судов по каждому из фарватеров с опорой на ICLSGNet была меньше, чем по любому из прочих алгоритмов. Последнее неудивительно, если принять во внимание, что ни один из них, например, не учитывал факта сходства трафика на некоторых фарватерах.

Планирование маршрута

Поиск оптимального пути судна, учитывая характеристики его движения, а также действующие на него внешние возмущения, является отнюдь не простой задачей,

традиционно решавшейся ранее с использованием динамического программирования и различных поисковых методов. Однако реализация соответствующих алгоритмов сталкивается, как правило, с непомерно высокими вычислительными затратами. Какие же подходы предлагает ИИ?

В одной из первых работ [11], где была применена ИИ-технология для устранения обсуждаемой проблемы, в качестве основного возмущающего фактора рассматривается океаническое течение и используется «обучение с подкреплением» (Reinforcement Learning – RL). Отличительной особенностью RL является способность формировать в системе управляющие сигналы в процессе активного взаимодействия с окружающей средой, даже если исходная информация о системе отсутствует. При этом чем лучше RL справляется с поставленной задачей, обеспечивая в итоге минимизацию времени перехода из начальной точки в конечную, тем большее «вознаграждение» получает соответствующий процесс (в этом и заключается «подкрепление»).

Существенно, что RL содержит соответствующую структуру, позволяющую включить в процесс решения задачи модель движения судна в условиях окружающей среды. Так, океанические приливные течения, являясь периодическими во времени, имеют, тем не менее, сложные распределения, в связи с чем в работе предлагается их картографировать. В примененном алгоритме данные о течении задавались в табличном виде.

Чтобы проверить эффективность предложенного алгоритма, полученные с его использованием результаты сопоставлялись с аналитическим решением задачи Цермело (Zermelo) [12], позволяющим оптимизировать управление движением судна с целью минимизации времени прохождения трассы с заданным полем течения. В рассмотренном примере, где скорость течения по маршруту существенным образом варьировалась по отношению к скорости судна, время движения по криволинейной трассе в соответствии с предложенным алгоритмом составило 1441,9 с, тогда как согласно аналитическому варианту – 1440 с. Одновременно формы пути в обоих случаях практически совпали, т.е. рассматриваемый алгоритм способен генерировать практически оптимальное решение. При этом, правда, не следует забывать, что в качестве внешнего возмущения учитывалось только течение, а трасса была проложена в открытом море без препятствий.

Идея привлечения RL для планирования маршрута БЭС с учетом требований COLREGs, к тому же в отсутствие данных об окружающей среде, получила развитие в работе [13]. В основе соответствующего решения рассматриваемой проблемы лежит широко используемый в задачах непрерывного управления метод «глубокого обучения с подкреплением» (Deep Reinforcement Learning – DRL), где ГО, обрабатывая входные данные, выделяет релевантные факторы, влияющие на изучаемый процесс. При этом RL способствует принятию решения, обеспечивающего достижение поставленной цели.

Для решения задачи планирования маршрута в статье [14] привлекается алгоритм DDPG, реализующий непрерывное взаимодействие с окружающей средой и учет данных предыдущих плаваний, а требования COLREGs в процессе навигации и при расхождении со встречными судами и препятствиями трансформируются в зону с ограниченным доступом, обход которой осуществляется с привлечением искусственного потенциального поля (Artificial Potential Field – APF) [15].

В качестве текущей входной информации учитываются поставляемые интегрированной навигационной системой данные о местоположении судна от глобальной

навигационной спутниковой системы GPS, показания АИС, курсоуказателя, лага, эхолота и анемометра, а также определяемые радиолокатором дальности до встречаемых объектов. На выходе алгоритма мы имеем изменения курса и скорости судна.

В процессе валидации алгоритма рассматривались случаи расхождения с одним, двумя и тремя судами, движущимися как «лоб в лоб» или обгоняющими собственное судно, так и пересекающимися курсами. На первом этапе использовался лишь алгоритм DDPG, который обеспечил полное соответствие в ходе плавания требованиям COLREGs, однако в ряде случаев привел к значительному увеличению пути при достижении конечной точки. На втором этапе был задействован алгоритм DDPG + APF, который не только сократил длину проходимого пути, но и повысил скорость сходимости решения задачи.

Прогноз траектории

Если число статей, в которых обсуждаются прогноз морского трафика и планирование маршрута судна на базе НС-технологий, невелико, то предсказанию его траектории с привлечением НС посвящено весьма значительное количество работ. В большинстве случаев решение задачи базируется на информации о траектории плавания, поставляемой АИС и хранящейся в базах данных по тому или иному региону плавания. Как правило, данные о начальном участке траектории используются для обучения НС, а остальные выступают в виде эталона для сопоставления с результатами прогноза. При этом во всех далее рассмотренных работах на первом этапе значительное внимание уделяется предварительной обработке данных, включая кластеризацию с целью отнесения траектории к тому или иному типу судна, отбраковку ложных данных и т.д. Учитывая, что соответствующие преобразования осуществляются без привлечения НС-процедур, анализ этого материала статей опущен.

Одно из первых исследований такого рода описывается в статье [16], где авторы назвали используемую НС сетью несуществующего ВР-типа. На деле с ВР ее связывает лишь то, что она обучается с помощью ВР-процедуры. В рассматриваемом случае НС обрабатывала данные о широте φ , долготе λ , скорости v и курсе k , поставляемые АИС в процессе плавания судна по реке Хуанпу, протекающей в Шанхае. Эта информация на каждом шаге работы НС снималась в 4 последовательные момента времени, из которых данные первых трех циклов образовывали 12-размерный вектор входных данных, а данные последнего – 4-мерный вектор выходных данных, при обучении НС принимаемых за эталон. В итоге входной слой НС имел 12 нейронов, выходной – 4; в скрытом слое было 12 нейронов. Критерием минимизации невязки на выходе НС, формируемой в виде разности между эталонными значениями φ_4 , λ_4 , v_4 и k_4 и величинами на выходе НС на тот же момент времени, представляющими собой прогноз траектории судна, выступала СКП.

Собранные в процессе решения задачи данные были распределены следующим образом: 70% использовались для обучения НС и 30% – для ее тестирования. В статье приведен пример прогнозирования траектории на 1 мин при движении судна в течение 20 мин. Нормированная погрешность прогноза на этом интервале составила $1 \pm 0,1$. Приведен и результат решения задачи с применением некоего фильтра калмановского типа, где эта погрешность на указанном интервале нарастает от 1,8 до 2,6. Комментировать этот результат бессмысленно, т.к. в работе не приводятся по этому фильтру никакие данные, так что о его адекватности поставленной задаче судить невозможно.

Годом позже вышла статья [17], в которой была применена RNN-сеть, построенная на управляемых рекуррентных блоках (Gated Recurrent Unit – GRU). По структуре такая НС похожа на LSTM, но с вычислительной точки зрения обладает преимуществом за счет того, что в ней «входной» клапан (gate) и так называемые «забывания», характерные для LSTM, объединены в клапан «обновления», который управляет тем, какое количество прошлой информации следует учесть на текущем шаге работы НС. Имея за счет этого меньшее количество параметров, GRU в большинстве случаев обеспечивает, тем не менее, сопоставимую с LSTM точность решения задач. Впрочем, за все приходится платить: в результате GRU-продукты склонны к «затуханию» градиента при обучении НС, что, как указывалось ранее, затягивает (если не останавливает) эту процедуру. LSTM-сеть лишена этого недостатка.

В [17] были подвергнуты обработке данные, снятые с АИС в районе порта Чжэнчжоу (провинция Хэнань, Китай). Одновременно по этим же данным была построена и НС типа LSTM, а также применен для решения задачи EKF (Extended Kalman Filter – расширенный фильтр Калмана (ФК)). При обучении в качестве нормы погрешности использовалась СКП. Для обучения НС GRU в среднем требовалось 30 циклов, LSTM – 50. При 30 циклах обучения GRU вероятность корректного прогноза траектории составляла 0,96, а при 200–300 – 0,98, что опередило результаты LSTM.

При тестовых испытаниях было задействовано 330 наборов траекторных данных. По сравнению с EKF применение НС дало лучшие результаты, что, по мнению авторов статьи, было обусловлено существенной нелинейностью задачи (на траектории имелись значительные изменения курса в конце движения судна). Вероятность корректного прогноза траектории с помощью GRU и LSTM оказалась сопоставимой и приближалась к 0,99.

В работе [18] траектория прогнозировалась с использованием НС типа «последовательность в последовательность» (sequence-to-sequence – seq2seq), базовая архитектура которой состоит из двух НС RNN-типа (как правило, моделей GRU или LSTM) – кодировщика, который обрабатывает входную информацию, и декодера, генерирующего данные вывода, а также содержит промежуточные слои для выявления пространственно-временных зависимостей в анализируемых последовательностях. Отличительной особенностью предлагаемого в статье подхода является привлечение передаваемой АИС информации не только о траектории как таковой, характеризующей широтой и долготой каждой ее точки, но и о месте следования судна (такие траектории авторы относят к маркированным).

В качестве кодировщика в НС применялась двунаправленная LSTM (Bi-LSTM), один уровень которой обрабатывал входные данные в прямом направлении, а второй – в обратном, что позволяло модели лучше понимать взаимосвязь между элементами последовательности и с большей вероятностью сохранять информацию, которая могла быть утрачена в стандартной LSTM при значительной ее длине. Основу декодера составила LSTM прямого распространения (feed – forward), где передача информации осуществляется напрямую от входного слоя НС к выходному.

В эксперименте, проводившемся авторами [18], использовались данные по траекториям плавания танкеров в водах Дании, хранящиеся Датским морским управлением (Danish Maritime Authority) в открытом доступе. При этом анализировались траектории при длительности плавания в 3 часа с периодом выборки 15 мин. Критерием оценки качества прогноза служила СКП. Кроме результатов, достигнутых

благодаря алгоритму sec2sec, в работе приводятся СКП (в морских милях) прогноза траектории, выполненного с применением алгоритмов линейной регрессии (ЛР) и многослойного персептрона (МП). МП представляет собой НС прямого распространения сигнала (без обратных связей), состоящую из входного, одного или нескольких скрытых и выходного слоев, при этом, как правило, в качестве функции активации выступает сигмоида. В табл. 1 под немаркированными данными понимаются полученные без учета места следования судна, а величины 1–3 ч характеризуют горизонт прогноза.

Как следует из таблицы, архитектура sec2sec дает наилучшие результаты для каждого рассматриваемого горизонта прогнозирования как в маркированных, так и в немаркированных экспериментах. Сравнивая полученные данные, легко установить, что модели МП и sec2sec в отличие от ЛР эффективнее используют маркировку траектории. Существенно, что маркировка особенно важна для долгосрочного прогнозирования. Действительно, хотя и немаркированные МП и sec2sec достигают приемлемого качества прогнозирования в краткосрочной перспективе, для более длительных временных горизонтов привлечение немаркированной траектории быстро ухудшает результат.

Т а б л и ц а 1

	Немаркированные			Маркированные		
	1 ч	2 ч	3 ч	1 ч	2 ч	3 ч
ЛР	1,51	3,99	7,12	1,48	3,74	6,14
МП	0,89	2,13	4,01	0,67	1,24	1,96
sec2sec	0,78	1,93	3,66	0,56	1,08	1,73

Развитием идей предыдущей статьи стала работа [19], авторы которой сконцентрировали свое внимание на том, что данные о траектории судна являются функцией как координат, так и времени. Предложив считать долготу и широту места судна двумерными величинами, они учли свойство НС CNN-типа выделять в последовательностях пространственные связи и, сохранив структуру НС sec2sec в целом, на замену применявшейся ранее LSTM типа RNN ввели НС ConvLSTM, способную эффективно обрабатывать пространственно-временные последовательности.

В итоге предложенная модель состоит из слоев кодировщика и декодера, построенных с помощью ConvLSTM, и сверточного слоя. Для реализации ConvLSTM используются те же уравнения, что и при имплементации LSTM, в которых при обработке входных данных весовые матрицы заменяются операциями свертки. Кроме того, если в стандартной LSTM роль функций активации обычно выполняют сигмоида и гиперболический тангенс, то в рассматриваемой работе вместо последнего применяется выпрямленная функция линейной активации (Rectified Linear Unite – ReLU), решающая проблему затухания градиента [20].

Эффективность предложенной модели проверялась на снятых с помощью АИС траекториях ходящего по Янцзы (Китай) грузового судна сопоставлением с результатами использования модели LSTM – sec2sec, полученными в работе [18], где для корректности сравнения гиперболический тангенс был заменен на ReLU. В табл. 2 приводится средняя СКП прогноза в метрах для горизонта предсказания в 10, 15 и 20 мин (обрабатывались 184 непрямолинейные траектории).

Т а б л и ц а 2

	10	15	20
LSTM – sec2sec	138	208	197
ConvLSTM – sec2sec	69	70	124

Из этих данных с очевидностью следует преимущество предложенного варианта НС по сравнению с ранее разработанным.

В 2017 г. вышла статья [21], ознаменовавшая появление одной из самых популярных НС последнего времени – Transformer (Трансформер), главная отличительная особенность которой – наличие механизма self-attention, переводимого «в лоб» в русскоязычной литературе как «внимание», мы в дальнейшем будем называть его «самооценкой». Именно этот механизм, применяемый к элементам входной последовательности, позволяет Transformer понять, какая ее часть наиболее релевантна решаемой задаче. Эффективность Transformer обусловлена способностью организовывать параллельные вычисления. В обеспечение последних в НС предусмотрен механизм позиционного кодирования, когда каждый элемент на ее входе снабжается неким маркером, определяющим положение элемента в обрабатываемой последовательности. НС Transformer показала весьма высокую производительность в обработке пространственно-временных данных. Одновременно достаточно часто применяется следующий подход: вначале моделируемая последовательность обрабатывается с помощью Transformer, после чего ее выходы подаются на вход НС того или иного типа.

По этому пути при прогнозировании траектории пошли и авторы [22]. Во введении они отмечают, что при использовании LSTM наблюдаются следующие проблемы НС:

- 1) эффективно оценивая временные характеристики последовательностей, она не столь успешно обрабатывает пространственные (в нашем случае связанные с перемещением судна по траектории);
- 2) плохо справляется с решением задачи, если отсутствует часть данных при их съеме с определенной скважностью.

Оба эти недостатка не присущи Transformer. Эффективное моделирование пространственно-временных процессов с ее привлечением было отмечено ранее, решению же второй проблемы способствует позиционное кодирование. Да, соответствующее измерение не поступит на вход НС, но анализ упомянутых маркеров выявит этот факт и будут приняты соответствующие алгоритмические меры.

С учетом этого авторами [22] была предложена интегрированная НС типа TRFM–LS (Transformer + LSTM), которая обучалась на массиве АИС-данных, собранных в районе самого загруженного порта в мире – Нинбо-Джоушань (провинция Чжэцзянь, Китай). Как и в предыдущих случаях, качество ее функционирования проверялось сопоставлением результатов прогнозирования траектории, полученных с помощью как TRFM–LS, так и целого ряда современных типов НС, включая LSTM и Bi-LSTM. Прежде всего следует отметить быструю сходимость алгоритма решения задачи (достаточно было 150-200 циклов решения), обусловленную параллельными вычислениями в Transformer. Что касается прогноза траектории, то авторы не озаботились приведением в статье каких-либо численных данных, а зафиксировали значительное количество графических примеров, из которых с очевидностью следует, что TRFM–LS существенно эффективнее решает поставленную задачу: по-

строенная с ее использованием прогнозная траектория располагается гораздо ближе к эталонной, чем траектории, рассчитанные посредством LSTM и Bi-LSTM.

В результате у читателя может сложиться мнение, что включение Transformer в тот или иной алгоритм закрывает проблему точности прогнозирования траектории судна. Увы... В 2024 г. выходит статья [23], которая похоронила эти надежды. В ней была предложена НС типа DBDIE (Deep Bi-Directional Information-Empowered), сформированная на базе двунаправленной LSTM (Bi-LSTM) и двунаправленной GRU (Bi-GRU) НС, выходы которых комплексированы за счет оригинального механизма самооценки.

Эффективность предложенной модели проверялась в том числе на АИС-данных, аккумулированных в рамках 2000 траекторий движения судов в районе порта Шэньчжэнь (провинция Гуандун, Китай), сопоставлением с результатами, полученными с применением НС RNN, LSTM, GRU, Bi-LSTM, Bi-GRU, Sec2Sec и Transformer. По обыкновению, 80% данных были задействованы для обучения и 20% – для тестирования.

В первом эксперименте (верхняя строка в табл. 3) данные Bi-LSTM принимались при комплексировании с весом 0,52, а Bi-GRU – с весом 0,48. Во втором эксперименте (вторая строка) при комплексировании уже использовался механизм самооценки. Цифры (в процентах) отражают, на какую величину СКП решения задачи с помощью той или иной НС превышают результат решения с применением НС DBDIE.

Т а б л и ц а 3

Bi-GRU	Bi-LSTM	GRU	LSTM	Transformer	RNN	Sec2Sec
7	10	15	24	49	79	100
32	40	48	52	60	61	48

Из приведенного следует, во-первых, что НС Transformer – отнюдь не панацея при решении задачи прогноза траектории, а во-вторых, что механизм самооценки весьма эффективен.

Подводя итоги рассмотренному в данном разделе, будем иметь в виду следующее: нет никаких гарантий, что применение предложенных алгоритмов в других обстоятельствах позволит сохранить вывод о преимуществе того или иного из них. Начнем с того, что каждому из них свойственна оригинальная процедура предварительной обработки «сырых» данных АИС, учитывающая специфику имеющегося материала. В силу этого при обработке датасета, сформированного в том числе из данных АИС в иных внешних условиях, эффективность предложенной НС изменится. Далее ни в одной из статей не обсуждается работоспособность предложенных алгоритмов применительно к различным типам судов (очевидно, что прогнозирование траектории супертанкера и буксира – не одно и то же). Наконец, с очевидностью можно констатировать, что поиск наиболее эффективных типов НС для прогноза траектории судна продолжается.

Обнаружение объектов и их классификация

Следующей задачей, характерной для судовождения, является обнаружение морских объектов и их классификация (последнее чрезвычайно важно в военно-морских применениях). В большинстве работ, опубликованных на конец 2017 г., при

решении этой проблемы данные, поставляемые оптическими или инфракрасными датчиками, использовались автономно, и классификация объектов осуществлялась с помощью алгоритмов, в основе которых лежит метод опорных векторов (support vector machines – SVMs), информацию о нем можно найти в [24].

По иному пути пошли авторы [25]. На первом этапе обработка данных оптического и инфракрасного канала проводилась также автономно, чтобы оценить качество классификации в этом случае. На втором этапе задача классификации решалась при комплексировании данных. Процедура обнаружения объектов предусматривала привлечение в каждом канале предложенной в [26] НС CAFFE (Convolutional Architecture for Fast Feature Embedding) CNN-типа. CAFFENet в каждом канале обучалась независимо. Классификация осуществлялась с помощью функции активации softmax, преобразующей величины на ее входе в интервал (0,1) с суммой равной 1, что позволяет трактовать величины на выходе softmax как вероятности.

В эксперименте был задействован датасет VAIS [27] – единственная существовавшая на момент выхода статьи база для оптических и инфракрасных данных применительно к 6 категориям судов: грузовым, парусным, средним пассажирским, средним иного назначения, буксирным и малоразмерным. Авторы использовали 544 пар изображений судов для обучения и 360 для валидации. Кроме того, они сформировали еще 107 пар: 66 снятых в идеальных условиях и 41 в условиях тумана, засветок солнцем и слабой освещенности.

При обработке данных VAIS были получены приведенные в табл. 4 параметры правильной классификации судов.

Т а б л и ц а 4

Класс судна	Инфракрасный канал	Оптический канал	Интегрированный вариант
Грузовое	76,7%	85,0%	93,3%
Пассажирское	61,7%	81,7%	83,3%
Парусное	61,7%	76,7%	90,0%
Буксирное	51,7%	85,0%	88,3%

Результаты классификации сформированных авторами пар изображений при комплексной обработке таковы: в идеальных условиях в среднем достоверность ее составляет 87%, в противном случае – 79,2%.

В [28] классификация судна производится посредством сверточной НС Faster R-CNN [29] – модификацией НС Fast R-CNN [30]. На этапе обнаружения объектов первым делом последовательность изображений разбивается на области, где вероятно их нахождение. В [30] для этого используется селективный поиск, опирающийся на выявленные при обработке изображений признаки соответствия заданным классам объектов и занимающий значительное время. В Faster R-CNN это поручено модулю RPN (Region Proposed Network), генерирующему предположения о местонахождении таких областей, что резко упрощает их обнаружение с применением на следующем шаге НС Fast R-CNN.

Для проведения эксперимента с помощью Google было выбрано 7000 изображений судов, относящихся к 7 классам – по 1000 для каждого. 750 из них предназначались для обучения НС, а 250 – для контроля качества ее работы. Результаты

испытаний таковы: авианосец – 90,6; эсминец – 88,0; подводная лодка – 90,2; контейнеровоз – 99,6; сухогруз – 99,6; круизный лайнер – 99,6; буксир – 95,0 (цифры означают вероятность классификации судна в процентах).

Начиная с 2016 г. на смену HC семейства R-CNN для обнаружения и классификации объектов приходят HC типа YOLO (You Only Look Once – «вы смотрите только раз») [31]. Основное отличие YOLO от R-CNN заключается в том, что она эффективно опознает объекты в режиме реального времени. Принцип работы YOLO подразумевает ввод сразу всего изображения, которое проходит через CNN только один раз, в силу чего эта HC обладает преимуществом высокого быстродействия. В основе алгоритма YOLO лежит разбиение изображения на сетку, образованную из $(n \times n)$ ячеек, имеющих несколько ограничивающих рамок в виде прямоугольников (квадратов), для каждой из которых устанавливаются положение центра, ширина и высота, и играющих при обработке изображения роль своеобразных «якорей» (эта концепция была предложена в статье [29]). Одновременно для каждой ячейки прогнозируется вероятность отнесения содержащейся в ней картинки к тому или иному классу объектов. Далее после выполнения ряда процедур фиксируются итоговое положение «якоря», размеры ограничивающей рамки, подтверждается вероятность того, что объект в рамке относится к тому или иному классу, и тем самым завершается процесс локализации и классификации.

Результаты привлечения технологии YOLO для обнаружения морских объектов и их классификации описаны в статье [32], посвященной прежде всего выявлению БЭС. Используемая в исследовании HC RDCNN (The Regressive Deep Convolutional Neural Network – регрессионная глубокая сверточная нейронная сеть) базируется на версиях YOLOv2 и YOLOv3, в частности на идее применения слоя типа FPN (Feature Pyramid Networks), который позволяет извлекать признаки объектов интересующих нас классов, и функции активации Leaky ReLu (ReLU «с утечкой»).

В эксперименте по проверке эффективности работы RDCNN были задействованы изображения судов следующих семи классов: корабля береговой охраны, контейнеровоза, круизного судна, парома, рыболовного судна, парусника и яхты. Как и ранее, сопоставлялись результаты, полученные при применении HC RDCNN, Fast R-CNN, Faster R-CNN и YOLOv2 по таким параметрам, как mAP (средняя по 7 классам объектов вероятность правильной их классификации) и число обработки кадров в секунду FPS. При этом, что весьма важно, датасет, с которым работала HC RDCNN, содержал лишь 4200 изображений, во всех остальных случаях – 11 126. Данные табл. 5 подтверждают существенное превосходство HC RDCNN над конкурентами.

Т а б л и ц а 5

Тип HC	mAP	FPS
Fast R-CNN	0,710	0,5
Faster R-CNN	0,892	15
YOLOv2	0,830	83
RDCNN	0,921	78-80

Вместе с тем технологии обнаружения, основанные на применении «якорей», не лишены недостатков. Вызвано это прежде всего необходимостью тщательно на-

страивать заранее размеры и соотношения их сторон, а для разных наборов данных и перенастраивать их. Плотное распределение «якорей» приводит к большим вычислительным затратам при обучении. Чтобы избежать этих неприятностей, в статье [33] предложена НС типа DCNN, способная при обработке изображений автоматически строить карту признаков, характеризующих классы изучаемых объектов. В ней «якоря» заменены детектором на основе центральной точки (Central point based Ship Predictor – CSP), имеющим 3 ветви: 1) прогнозирования положения центра объекта; 2) оценки длины и ширины объекта; 3) оценки смещения центра объекта при понижении частоты дискретизации в процессе обработки изображения, – выходы которых подвергаются комплексированию.

Одновременно были предприняты меры для повышения быстродействия алгоритма. Так, на первом этапе построения карты признаков используется облегченный экстрактор на базе MobileNetv2 [34], позволяющий обрабатывать разномасштабные изображения.

Эффективность DCNN, как и во всех предыдущих случаях, оценивалась сопоставлением с продуктивностью уже известных нам НС Faster-RCNN и YOLOv3, а также предложенной в [35] НС RetinaNet, основанной на применении упоминавшегося ранее FPN. Датасетом служил Air-sar-ship1-1.0 [36], представляющий собой набор из 31 изображения судна Gaofen-3, полученного с помощью радара с синтезированной апертурой. Из них 21 снимок был выбран для обучения и 10 – для тестирования НС. Вероятность обнаружения при этом составила (в процентах): Faster-RCNN – 73,49; YOLOv3 – 63,87; RetinaNet – 72,12; DCNN – 85,03. Как и во всех предыдущих случаях, новый алгоритм оказался наилучшим, а наихудшим при этом, что удивительно, – YOLOv3.

Несмотря на только что сделанную ремарку в отношении YOLOv3, в 2021 г. вышли 2 статьи [37, 38], в которых рассматривались модернизация алгоритма этой НС, предназначенного для обнаружения и классификации морских судов, и способы увеличения скорости решения задачи. Сконцентрируемся на первой из них, где описываются следующие усовершенствования:

- 1) предварительно установленные «якоря» имеют такую же «приземистую» форму, как и сами суда, что повышает качество обучения НС;
- 2) примененный слой свертки способствует повышению качества обнаружения мелких объектов;
- 3) в связи с тем что обработка крупномасштабных изображений судов усложняется на фоне береговых сооружений, интенсивных солнечных бликов на поверхности воды и значительного волнения, в НС был введен специализированный модуль самооценки, который придал модели большую сфокусированность на целевой задаче.

Разработанный алгоритм SDVI может использоваться в видеонаблюдении для точной классификации и позиционирования 6 типов судов (включая рудовоз, сухогруз, судно для перевозки генеральных грузов, контейнеровоз, рыболовное судно и пассажирское судно), осуществляемых в реальном времени. Если в стандартной YOLOv3 в процессе классификации задействовались 53 сверточных слоя, то в SDVI их всего 7, что приводило к снижению точности решения задачи, которая оставалась, тем не менее, приемлемой для опознавания судна, но быстродействие повышалось, что и было целью авторов.

Описанные в [37] эксперименты проводились с привлечением датасета SeaShips из работы [39]. Как и в предыдущих случаях, эффективность SDVI проверялась в сопоставлении с ранее обсуждавшимися НС, результаты – в табл. 6.

Т а б л и ц а 6

Модель	mAP	FPS
Fast R-CNN	0,70	0,50
Faster R-CNN	0,73	10
YOLOv2	0,77	86
YOLOv3	0,79	70
SDVI	0,74	135

Из данных таблицы следует: да, средняя (по 6 типам судов) вероятность верной классификации судов при использовании алгоритма SDVI по сравнению с YOLOv3 падает на 6-7%, но зато скорость обработки изображений возрастает практически вдвое.

В рассмотренных ранее публикациях речь шла о НС YOLO версии не выше v3. В связи с этим представляют интерес приведенные в статье [78] результаты применения НС YOLOv7-CSAW, опирающейся на НС YOLO версии v7 и, в частности, на алгоритм определения оптимального размера «якорей», что гарантирует их точное соответствие реальным предметам, а также механизм самооценки. Привлечение этой НС позволило обеспечить обнаружение в море малых объектов.

В описанном в статье эксперименте обрабатывался набор из следующих объектов такого типа: человек, доска, лодка, буй, парусная лодка и каяк. Их распознавание выполнялось с применением 6 алгоритмов и привело к следующим результатам: YOLOv3 (2018) – 68,6%, YOLOv4 (2020) – 71,1%, Faster-RCNN (2020) – 79,0%, Retina Net (2017) – 79,8%, YOLOv7 (2023) – 75,7% и YOLOv7-CSAW – 86,4%. Преимущество последнего алгоритма очевидно.

Подводя итоги краткому обзору технологий, используемых для обнаружения и классификации морских объектов, можем констатировать, что наиболее востребованы при этом НС типа R-CNN и YOLO, также относящиеся к типу CNN. Последнее неудивительно, т.к. процедура обнаружения и классификации судна в определенной степени эквивалентна задаче распознавания объектов, решаемой системами технического зрения, где применение CNN-сетей, позволяющих выделить важнейшие признаки изображения (например, края и формы), является определяющим [71]. И если при прогнозировании траектории приходилось заниматься поиском приемлемой НС, то для обнаружения и классификации морских объектов путь был проторен ранее выполненными исследованиями.

Решение задачи расхождения судов

Традиционно задача расхождения судов решалась с использованием средств автоматической радиолокационной прокладки (САРП), что полностью удовлетворяло требованиям COLREGs в этой части. Подключение в последние годы к САРП информации от АИС, с одной стороны, повысило достоверность предоставляемых судоводителю данных, а с другой – увеличило нагрузку на него в самый напряженный момент его деятельности, не обеспечив автоматическое расхождение судов.

Сложность проблемы расхождения судовкратно возросла с появлением БЭС. Нельзя не согласиться с автором публикации [40], что в этом случае необходимо иметь алгоритм, способный реализовывать следующие процедуры:

- обнаружения и классификации встречных объектов;
- расхождения (с учетом требований COLREGs) как с одним, так и с несколькими судами и стационарными объектами на безопасном расстоянии;
- маневрирования при расхождении, в том числе посредством изменения как курса, так и скорости с одновременным учетом гидродинамических характеристик судна, ветра, течения и волнения.

Что же привнесло внедрение в этот процесс НС-технологий? Обратимся для этого к публикациям последнего пятилетия.

Первым делом проанализируем работу [41], где описывается алгоритм автоматического предотвращения столкновений судов (ПСС) на основе DRL и для оценки риска столкновения используется понятие «зона помехи, определяемая целью» (obstacle zone by target – OZT). Под OZT имеется в виду область возможного столкновения судов в процессе их движения, а в качестве представления такого события рассматриваются сценарии, предложенные Имадзу (Imazu) в работе [42] с учетом требований COLREGs. При решении задачи расхождения максимальная длина судна принималась равной 300 м, а минимальное расстояние между судами при безопасном маневрировании – 0,5 морской мили; скорость движения судов – 12 узлов. Алгоритм расхождения базируется на НС RNN-типа, обучение которой осуществлялось с помощью инструментария Open AI Gym [43], традиционно применяемого в последнее время при разработке DRL.

Очевидно, что величина OZT может быть рассчитана с привлечением традиционных для решения задачи расхождения понятий расстояния до кратчайшей точки сближения (closest point of approach – CPA) и времени движения до CPA (TCPA), однако их чрезвычайно сложно встроить в процесс проектирования НС. В связи с этим в работе в качестве поставщика информации на входе НС задействуется виртуальный датчик, представляющий собой своеобразную сетку, перекрывающую OZT, форма которой в статье принята в виде капсулы, а параметры определяются на основе данных о дальности до CPA и TCPA. При этом для каждого встречного судна (в статье обсуждается расхождение максимум с тремя из них) строится своя OZT, после фиксации преобразуемая в вектор, размерность которого равна числу ячеек в сетке; он и используется на входе в DRL.

Предполагалось, что плавание происходит в открытом море и маневрирование осуществляется только изменением курса своего судна, которое описывалось уравнением, предложенным Намото (Namoto) [44]. Под успешным решением задачи понималось перемещение из точки А в точку Б без попадания своего судна в зону OZT. Роль DRL выполняла уже знакомая нам НС типа LSTM, на вход которой поступает информация от виртуального датчика, а также данные о динамике судна и точках поворота на трассе, а на выходе имеются данные, дискретно или непрерывно выдаваемые непосредственно на перо руля или в авторулевой (рассматриваются два варианта управления).

Всего рассмотрено 23 схемы расхождения судов. В процессе моделирования выяснилось, что при дискретной выдаче данных не всякий раз удается удовлетворить требованиям COLREGs. Во всех случаях величина минимального расстояния при расхождении с опорой на авторулевой была больше, чем при выдаче данных непосредственно на руль. И хотя всегда удавалось удачно решить задачу расхождения,

нельзя не отметить, что при этом свое судно не было стабильным на курсе, что не может не смущать судоводителей встречных судов.

Технологию DRL для удержания БЭС на заданной траектории с одновременным расхождением со встречными судами с учетом требований COLREGs применили и авторы статьи [45]. При описании динамики судна в горизонтальной плоскости они воспользовались моделью, предложенной Фоссеном (Fossen) [46], и учитывали возмущения, вызванные внешней средой. Удержание судна на траектории, задаваемой отрезками прямой и точками поворота, осуществляется в работе с помощью предложенного тем же Фоссеном метода line-of-sight (линии визирования) [47], аналогом которому может служить наведение на цель летательных аппаратов по методу трех точек [48].

Для построения НС авторы формируют 2 вектора, определяющие состояние своего судна и встречного. В состав первого вектора входят поперечное отклонение от траектории, погрешности знания курса и путевого угла и угловых скоростей их изменения, расстояние до точки прибытия и пеленг на нее, а также угол поворота руля, скорость его изменения и длина судна. Второй содержит информацию о положении и скорости встречного судна (в локальной системе координат, связанной с БЭС), расстоянии между судами, пеленге с одного судна на другое и длине встречного судна.

Обработывая эти данные в соответствии с DRL-концепцией, предложенная авторами НС формирует управление движением БЭС, выдавая на выходе сигнал для изменения положения пера руля в соответствии с принятой при ее проектировании стратегией. В результате при взаимодействии с внешней средой вырабатывается некое «вознаграждение» (это, как уже указывалось ранее, и есть «подкрепление» в DRL). Оно считается «положительным» при обеспечении целевой функции решения задачи и «отрицательным» при столкновении с встречным судном или недостижении точки прибытия. В то же время наилучшей стратегией является та, для которой суммарное «вознаграждение» при прохождении трассы будет минимальным, что обеспечивается применением алгоритма PPO (Proximal Policy Optimization) [49].

В результате моделирования удержания БЭС на траектории (без решения задачи расхождения) после 20 циклов обучения НС при наличии 4-х точек поворота, воздействии волн, ветра и течения погрешность отклонения от траектории в наихудшем случае не превысила 7 м. В среднем по всем экспериментам эта цифра составила 1,8 м.

При решении задачи расхождения рассматривались 2 судна, движущиеся соответственно встречными и пересекающими траекторию БЭС курсами, а также догоняющие его. Размеры их характеризовались кругом с радиусом от 25 до 100 м, скорость их была постоянной. БЭС имел длину 48 м, ширину 8,6 м и скорость 16 узлов. Расхождение с судами (оно выполнялось последовательно с каждым из них) всегда было успешным. Движение встречными курсами потребовало 1580 циклов обучения, и минимальное расстояние между судами составило 400 м.

Если в предыдущих двух случаях изучалось ПСС на примере двух судов, то с учетом требований COLREGs в работе [50] предложен алгоритм CA-QMIX расхождения уже нескольких объектов, разработанный на основе мультиагентного DRL. Для моделирования движения судов использовалась ранее упомянутая модель Номото с тремя степенями свободы.

Авторы предложили свести ПСС к двум ситуациям:

- 1) расходятся 2 судна – собственное рассматривается как агент, встречное – как динамическое препятствие;

- 2) расходятся несколько судов одновременно – каждое судно является агентом, и между ними существуют некие «партнерские» отношения.

Столкновение судов предотвращается ИИ-методом ORCA (Optimal Reciprocal Collision Avoidance) [51], формирующим для каждого агента зону, свободную от столкновений и представляющую собой в текущий момент окружность с радиусом R_{OS} для своего судна и R_{TS} – для остальных. Кроме того, с помощью этого метода рассчитывается скорость своего судна, обеспечивающая безопасное расхождение со встречающимися судами.

Что касается мультиагентного DRL, то авторами применяется схема централизованного обучения децентрализованному исполнению (Centralized Training Decentralized Execution – CTDE) [52]. При обучении НС DRL-типа в мультиагентном варианте имеются две трудности:

- 1) при взаимодействии с внешней средой агент получает информацию о ней только на локальном, а не глобальном уровне;
- 2) при совместном обучении агентов меняющиеся стратегии и действия порождают у разработчиков мнение, что процесс обучения нельзя стабилизировать.

Для борьбы с этими недостатками и предназначена CTDE.

Предложенный в работе алгоритм CA-QMIX был оценен с помощью имитационных тестов для различных внешних условий. Настройка сценариев моделирования ПСС предполагала ситуации столкновения как двух судов, так и нескольких. В первом случае моделирование использовалось для оценки того, соответствует ли алгоритм требованиям COLREGs. Во втором случае проверялась масштабируемость алгоритма, выходным параметром которого является угол перекладки пера руля.

Наибольший интерес вызывают приведенные в статье результаты моделирования процесса расхождения трех и четырех судов. В варианте расхождения трех судов удалось подтвердить возможность ПСС в том случае, когда маневрирование осуществляется за счет изменения как курса, так и скорости. При моделировании ПСС для четырех судов, двигавшихся с четырех сторон в одну и ту же точку, удалось не только решить задачу расхождения с выполнением требований COLREGs, но и доставить каждое судно в точку прибытия, что подтвердило высокую эффективность предложенного алгоритма.

Наконец, практически значимый случай изучен в статье [53], где рассматривается вариант подчиняющегося требованиям COLREGs мультиагентного расхождения БЭС и судов с экипажем, в том числе при нескоординированном (в отличие от работы [50]) их взаимодействии. Как и ранее, ПСС осуществляется на базе мультиагентного DRL [54]. Еще одна особенность проведенных исследований – моделирование с привлечением экспериментальных данных, и прежде всего АИС, по информации от которых в береговых системах было записано огромное количество сценариев морского движения, полезных для разработки алгоритмов автономного ПСС.

Под скоординированным расхождением в статье понимается поведение судна, имеющего атрибут обученного агента. Иначе говоря, судно принимает безопасные и соответствующие COLREGs меры по предотвращению столкновений, когда оно распознает их риск. Аналогично нескоординированное расхождение определяется как поведение судна, которое не имеет атрибута обученного агента – например, сохраняет скорость и курс и не принимает мер по предотвращению столкновений или действует не в соответствии с правилами. Для того чтобы смоделировать нескоординированные сценарии в реальных водах, в статье выбран метод взвешенной случайной выборки.

Для прогнозирования опасной зоны в статье используется предложенная в работе [42] OZT, виртуально увеличивающая размер препятствия, что приводит к заблаговременному началу решения задачи расхождения. Для определения размеров зоны привлекаются данные лидаров и видеокамер. Расхождение обеспечивается изменением курса судна. Модель движения судна – модель Намото с тремя степенями свободы.

При разработке алгоритма Per-DDQN авторы особое внимание уделили формированию функции «вознаграждения», являющейся одним из основных элементов DRL-технологий. Для скоординированных агентов она была задана по результатам анализа многочисленных данных о плаваниях судов различных типов, включая показания навигационных датчиков, о результатах ПСС и т.д. Для нескоординированных агентов функция «вознаграждения» была соответствующим образом модифицирована.

Обучение НС алгоритма Per-DDQN выполнялось на основании реальных данных, полученных при решении задачи расхождения для 12 судов в работе [55] и опирающихся на информацию АИС. Параметры своего судна были взяты из статьи [56] и соответствовали характеристикам БЭС «Ю Кун» (YU KUN).

С целью проверки эффективности алгоритма Per-DDQN было проанализировано 40 сценариев, базирующихся на идеях решения проблемы Имадзу. Если в первом из них рассматривалось расхождение двух судов, то в пятом – шести. При этом свое судно двигалось со скоростью 12 узлов. Минимальное расстояние при расхождении принималось равным 0,5 мили. В случае 6 судов, движущихся разными курсами, практически всем из них пришлось выполнить как минимум два последовательных маневра, чтобы избежать столкновения со встречными судами и тем самым удовлетворить требования COLREGs.

Одной из важнейших проблем при ПСС является необходимость обеспечить соблюдение правил расхождения судов, регламентируемых COLREGs и написанных с целью охвата как можно большего числа ситуаций в морских условиях чрезвычайно общо. Так, например, правило 15 гласит: «Когда два судна... идут пересекающимися курсами так, что возникает опасность столкновения, то судно, которое имеет другое на своей правой стороне, должно уступить дорогу другому судну, и при этом оно должно, если позволяют обстоятельства, избегать пересечения курса другого судна у него по носу».

Естественно, что интерпретация подобных правил программистами, пишущими программное обеспечение для ПСС, вызывает существенные затруднения. Именно поэтому ни в одной из ранее обсуждавшихся статей не раскрыт предложенный авторами механизм решения обсуждаемой проблемы, который они относят, судя по всему, к ноу-хау.

Впервые это сделано в исследовании [76], авторы которого предложили привлечь большие языковые модели (Large Language Model – LLM), представляющие собой подтип НС и созданные первоначально для работы лишь с текстовыми данными. В большинстве своем такие модели используют архитектуру Transformer, которая с помощью механизма самооценки позволяет выделять ключевую информацию и умеет работать с расплывчатыми и нечеткими запросами при обращении к НС. Модели эти зависят от гигантского количества параметров и обучаются на соответствующем объеме данных, что дает возможность задействовать их при решении широкого класса задач. Примерами таких моделей могут служить GPT-3 (175 миллиардов параметров!) и Chat GPT фирмы OpenAI (США), Giga Chat от Сбербанка,

способная обрабатывать и визуальные данные, и Yandex GPT от Яндекса, где аббревиатура GPT расшифровывается как Generative Pretrained Transformer («обученный генерации текста трансформер»).

Авторы [76] использовали для интерпретации правил COLREGs модель GPT-4 той же OpenAI, опустив какие-либо детали реализации соответствующей НС (опять-таки ноу-хау). Примечательно, что при этом не проводилось какой-либо дополнительной настройки модели применительно к морским условиям.

Алгоритм решения задачи содержит 4 блока:

- 1) описания задачи и формирования адекватного запроса на трактовку правил COLREGs (prompt engineering);
- 2) решения задачи ПСС, на вход которого непрерывно поступают данные об относительном курсе между своим и встречным судном, величинах риска столкновения судов (методика его расчета приведена в [77]), CPA и TCPA, а также о взаимном перемещении судов из блока 4;
- 3) объяснения предпринимаемых действий, где приводятся данные по исполняемому маневру, если он имеет место, и пояснения, чем он вызван;
- 4) описания окружающей обстановки, отражающего выполняемое маневрирование.

В статье приведены результаты моделирования задачи ПСС для четырех вариантов движения судов: встречного, обгоняющего, пересекающегося и неподвижного одного из них. Целью его являлось прежде всего подтверждение соответствия выполняемого маневра, отображаемого в блоке 3, правилам COLREGs, в связи с чем для описания движения судов использовалась упрощенная модель Номото. Во всех случаях такое подтверждение имело место, что позволило авторам статьи в заключении утверждать возможность применения предложенного алгоритма в качестве «средства помощи капитану при контроле за движением судов».

Завершая изложение решения задачи ПСС, отметим, что во всех рассмотренных статьях при этом реализуется DRL-технология в том или ином варианте аналогично тому, как она применялась и при планировании маршрута. И в том и в другом случае в конечном итоге результаты решения этих задач задействуются для непрерывного управления движением объекта, что, как правило, реализуется с помощью DRL, в том числе в мультиагентном варианте [72]. Последний подход позволяет решить первоочередную задачу судовождения – организации совместной эксплуатации БЭС и судов с экипажем, когда при их расхождении за корректное применение правил COLREGs отвечает вахтенный офицер, с одной стороны, и разработчик используемого БЭС алгоритма расхождения – с другой. Адекватность такого алгоритма правилам COLREGs подчас не гарантирована. Приведенные ранее примеры привлечения мультиагентного подхода поясняют, как сегодня пытаются разрешить эту коллизию.

Комплексирование ИНС/ГНСС

При комплексировании навигационных данных с применением ИИ наиболее часто возникает задача интегрирования информации, вырабатываемой инерциальными навигационными (ИНС) и глобальными навигационными спутниковыми системами (ГНСС), с одновременным исследованием точности таких комплексных систем в моменты пропадания ГНСС-сигнала. Далее мы рассмотрим решение этой задачи в ряде статей по мере их выхода.

Во вводной части статьи [57], воздав должное применению калмановской фильтрации в решении задачи ИНС/ГНСС, авторы отмечают, что в появившихся в начале 2000-х годов первых работах, где привлекались ИИ-идеи, были востребованы подходы, базирующиеся на многослойном персептроне [73] и радиальной базисной функции (РБФ) [74], игравшей роль функции активации и обеспечившей повышение скорости обучения НС (кроме многомерных случаев, когда это выполняется не всегда). При этом многослойная НС была неспособна корректно увязать погрешности ИНС при выработке координат в текущий момент с предыдущими их значениями. В самой статье [57], вышедшей на 15 лет позднее, используется НС RNN-типа, которая в силу рекуррентности лишена этого недостатка.




Рис. 2

В случае слабосвязанного комплексирования ИНС/ГНСС схема обучения RNN, которая реализуется при наличии данных о координатах и скорости от приемника ГНСС, представлена на рис. 2, где ψ – углы ориентации, δP – погрешность выработки координат интегрированной системой, а δv – скоростей.

В соответствии с равенством (16) [57] состояние памяти RNN S_t в момент времени t задается равенством $S_t = F(U \cdot x_t + W \cdot S_{t-1})$, где x_t – входные данные для НС, F – функция активации, U и W – соответствующие

веса. Из этого как раз и следует возможность RNN связывать текущую информацию с информацией на предыдущем шаге, что позволяет НС этого типа эффективно обрабатывать данные временных последовательностей.

Был проведен натурный эксперимент в процессе плавания судна из порта Санья (Китай) в Санкт-Петербург (Россия) с использованием ИНС МЭМС-типа с уходом гироскопа в $35^\circ/\text{с}$ и смещением нуля акселерометра в $0,01 \text{ mg}$. Эксперимент длился 10 часов, 8 из которых ушли на обучение RNN. В процессе его выполнения сигналы ГНСС отсутствовали лишь однократно в течение короткого времени. Полученные данные сопоставлялись с результатами, достигнутыми с применением EKF и НС (Extreme Learning Machine – ELM). СКП погрешности выработки координат в метрах были следующими: RNN – 19, ELM – 31 и EKF – 41. Такое же соотношение между погрешностями наблюдалось и при предварительном моделировании. Однако худшие среди представленных, как и выявленные при анализе работы [16], EKF-результаты, трудно объяснить, т.к. по самому фильтру в работе не приведено никаких данных. Возможно, это связано с некорректными моделями погрешностей измерителей.

Дальнейшее продвижение при решении задачи комплексирования ИНС/GPS сделано в [58]. При этом, если в [57] исследованию погрешностей интегрированной системы в случае пропадания сигнала ГНСС посвящен лишь один эксперимент, то в рассматриваемой работе ему уделено значительное внимание.

На рис. 3 представлена задействованная в исследовании схема интегрированной системы ИНС/GPS: a – в режиме обучения, b – в режиме прогноза. В том случае, когда сигналы GPS доступны, комплексирование осуществляется по слабосвязанной схеме с применением EKF (с одновременным обучением входящей в состав системы

НС – на рисунке она обозначена NN). При их отсутствии выходные данные системы формируются с учетом выходных параметров нелинейной авторегрессионной НС (Nonlinear Auto-Regressive – NAR), представляющей собой рекуррентную динамическую сеть, компенсирующую нарастающие погрешности ИНС.




Рис. 3

Эффективность предложенного решения с использованием ИНС на МЭМС-датчиках тестировалась в реальных условиях при размещении необходимой аппаратуры на автомобиле. Длительность двух тестов составила 700 с для каждого, во время которых после 600-й секунды сигнал GPS блокировался на 17 с. В первом случае выходы NAR были отключены. При их включении во втором случае на упомянутом 17-секундном интервале удалось снизить погрешность выработки широты на 82% и долготы на 67%, что с очевидностью свидетельствует о высокой результативности применения НС в предложенной схеме.

Оригинальный подход к комплексированию ИНС/GPS был предложен в статье [59]. Авторы ее отмечают, что моделирование выхода ИНС по координатам путем подачи на вход НС лишь вырабатываемых датчиками ИНС кажущегося ускорения и угловой скорости малоэффективно. В связи с этим на ее вход дополнительно подаются данные об углах ориентации и курсе. Одновременно из [60] заимствуется концепция ансамблевого машинного обучения (АМО), когда для моделирования выхода ИНС используется далеко не единственная НС (аналогом такого подхода при байесовской обработке является банк ФК). Одна из них, например, обслуживает случай стоянки объекта, а вторая – его движения (естественно, что они и обучаются на разных датасетах).

Для реализации АМО в [59] анализируются два подхода. Один из них – бэггинг (bagging), когда рассматриваются НС, которые, моделируя выходы ИНС, обучаются независимо и параллельно, а затем их результаты просто усредняются. Второй – бустинг (boosting), когда модели обучаются последовательно, причем последующая модель должна исправлять ошибки предыдущей (в работе конкретно используется LSBoot, проводящая среднеквадратическую минимизацию). Одновременно приводятся результаты применения не только АМО, но и многослойного персептрона (Multilayer Perceptron – MLP).

Структура системы при интегрировании ИНС/GPS аналогична в функциональном смысле представленной на рис. 2: при наличии сигналов GPS комплексирование осуществляется с помощью ФК, а при их отсутствии привлекаются данные АМО.

В работе [59] представлены результаты натурных испытаний системы при плавании судна в окрестностях порта Далян (Dalian, Китай) и использования ИНС навигационного класса. Интерес представляют лишь данные на период отсутствия сигналов GPS, т.к. при их наличии погрешность в выработке координат системой ИНС/GPS целиком определяется прецизионными данными GPS. Приведем погрешности (табл. 7),

вырабатываемые ИНС автономно и в интегрированном варианте ИНС/MLP, ИНС/LSBoot и ИНС/Bagging при определении координат в восточном направлении в метрах и в отсутствие сигналов GPS на интервалах 600, 1500 и 2500 с.

Т а б л и ц а 7

	ИНС	ИНС/MLP	ИНС/LSBoot	ИНС/Bagging
600	43,2	32,6	0,2	-112,8
1500	244,7	210,5	-9,1	-168,4
2500	458,6	432,9	71,7	-117,7

Из данных таблицы с очевидностью следует высокая эффективность применения комплексирования ИНС/GPS в варианте ИНС/LSBoot, в значительной степени парирующем нарастание погрешностей ИНС при отсутствии сигналов GPS.

Наконец, приведем новейшие результаты исследования этой же задачи в работе [61], где задействована иерархическая LSTM (HLSTM), предложенная в статье [62], каждый модуль которой определяется датчиком на его входе.

При использовании HLSTM неминуемо встает вопрос о правиле взвешивания вырабатываемой модулями информации, причем применение средних или медианных значений может оказаться не лучшим решением. В связи с этим в [61] разработан оригинальный вариант HLSTM на основе механизма самооценки, подобного механизму в НС «Трансформер» и реализованного в выходном слое НС, где осуществляется необходимое взвешивание. Мало того, в работе востребовано и ансамблевое моделирование, превращающее в итоге HLSTM в AHLSTM.

В отличие от ранее рассмотренных вариантов AHLSTM обучается оценивать измерения ГНСС, чтобы использовать эти оценки в слабосвязанной системе ИНС/ГНСС при пропадании сигналов последней. При их наличии комплексирование традиционно осуществляется с помощью ЕKF.

Обработка AHLSTM выполнялась во время полета дрона Skywalker в течение 30 минут при функционировании ИНС модели SPATIAL INS на частоте 50 Гц и приемника Ublox M8 GNSS на частоте 10 Гц. Ниже (табл. 8) приведены СКП вычисления определения координат в метрах в направлении на север и восток при отсутствии сигнала ГНСС (привлекались сигналы GPS, ГЛОНАСС и Галилео) в течение 160 с и различных способах обработки информации в интегрированной системе, включая НС RNN-типа.

Т а б л и ц а 8

	AHLSTM	HLSTM	LSTM	RNN	EKF
Север	14,1	56,0	57,3	447,0	214,6
Восток	48,3	59,0	276,3	325,0	282,4

Если учесть, что погрешности в столбце ЕKF при недоступности сигнала ГНСС в основном определяются погрешностями ИНС, то из приведенных данных следует, что применение AHLSTM в значительной степени позволяет компенсировать их нарастание.

Подводя итоги рассмотрению задач комплексирования ИНС/ГНСС в статьях [57, 58, 59, 61], прежде всего необходимо отметить широкий спектр задействуемых

при этом НС-технологий, что говорит об отсутствии в этом случае (в отличие от решения задачи ПСС) какого-либо единого подхода.

Завершая изложение материала этого раздела, нельзя не обратить внимания на следующее. Интерес к решению задачи комплексирования ИНС/ГНСС появился с созданием в конце 1960-х годов спутниковых радионавигационных систем «Транзит» (Transit, США) и «Цикада» (СССР). С тех пор было опубликовано несчетное число работ, где такое комплексирование в абсолютном большинстве случаев осуществлялось на основе байесовского подхода (прежде всего с привлечением фильтров калмановского типа), в принципе позволяющего достичь оптимального решения с оценкой погрешности получаемого результата. За эти годы удалось досконально изучить модели погрешностей как ГНСС, так и ИНС применительно как к платформенным, так и бесплатформенным системам при слабосвязанном и тесносвязанном интегрировании в линейной и нелинейной постановке. Более того, созданные на этой основе ИНС/ГНСС-системы демонстрируют достойные характеристики по определению местоположения подвижного объекта при использовании их на суше, в воде и воздухе.

Что же касается НС-подхода, разработчики которого отказываются от знания моделей погрешностей интегрируемых систем, то как в рассмотренных нами ранее, так и в проанализированных в обзорной статье [1] публикациях 2003–2017 гг., посвященных ИНС/ГНСС, удастся подтвердить лишь работоспособность предложенного алгоритма. Сравнение его с фильтрационным подходом либо не осуществляется вовсе, либо осуществляется таким образом, что корректность его невозможно проверить.

Последняя ремарка неминуемо приводит к выводу о необходимости всеобъемлющего сопоставления обсуждаемых способов решения задачи комплексирования навигационной информации (и не только применительно к ИНС/ГНСС), что не может являться предметом рассмотрения настоящей работы. Читателям, интересующимся данной проблематикой, можно порекомендовать ознакомиться с исследованиями [79], где такое сопоставление проведено достаточно общо, и [80], где оно выполняется на примере решения задачи прогноза качки.

Кибербезопасность и НС

Переходя к обсуждению вопроса обеспечения на море кибербезопасности при взаимодействии с ИИ-технологиями, следует иметь в виду [63], что борьба с киберугрозами применительно к морской навигации находится на начальной стадии, что, впрочем, неудивительно, так как на законодательном уровне она была инициирована лишь в январе 2021 г. Парадоксально, но с повышением уровня цифровизации процесса судовождения, к которому все стремятся, уровень киберугроз только возрастает. Это же имеет место и по мере появления судов-автоматов в связи с отсутствием на борту экипажа, который может оперативно парировать кибератаки. Более того, в этом случае мутирует и спектр борьбы с киберугрозами, смещаясь с бортовых процедур типа управления паролями на сетевые аспекты.

Если же говорить о БЭС, то придется признать, что ИИ-технологии приобретают исключительное значение при их разработке. Связано это с тем, что в процессе плаванья БЭС приходится принимать решения по реализации тех или иных процедур, будь то планирование маршрута, опознавание встречных судов или швартовка, основываясь на своем представлении об окружающей действительности, оценку которой без при-

влечения методов ИИ сделать практически невозможно. Как следствие, киберугрозам подвержены не только аппаратура БЭС, но и НС, реализующие те или иные функции.

Только что поднятый вопрос рассматривается в работе [63]. Учитывая, что проблемам кибербезопасности судовой аппаратуры посвящено значительное число исследований (из отечественных можно упомянуть [64]), сосредоточимся на борьбе с кибератаками по отношению к НС. Авторы [63] фиксируют следующие их варианты:

- 1) выявление уязвимых точек, обнаруженных на этапе обучения НС, в результате чего впоследствии НС будет принимать неверные решения;
- 2) атаки на данные датчиков, используемых в качестве входной информации для НС;
- 3) атаки на НС как таковую, например взлом или внедрение вредоносного ПО;
- 4) нарушение работы протокола связи. Так, шина CAN и протокол NMEA, используемые на судах, разработаны без учета требований безопасности. Шина CAN и стандарт NMEA, передающие данные без шифрования или аутентификации, уязвимы для атак типа «человек посередине» (Man-in-the-Middle), которые позволяют злоумышленнику манипулировать данными или собирать их и злонамеренно вставлять ошибки.

Как следствие, в статье предлагается методология проектирования требований к качеству безопасности (Security Quality Requirements Engineering), с помощью которой были определены цели обеспечения безопасности БЭС. Для НС это гарантия ее стабильности. Одновременно оценка рисков реализации киберугроз по отношению к НС на практике и применение критериев Международной ассоциации классификационных обществ (International Association of Classification Societies) позволили категорировать требования к обеспечению безопасности НС.

К высшей их категории были отнесены:

- 1) принятие мер по устранению каких-либо дефектов НС;
- 2) передача информации только в зашифрованном виде;
- 3) реализация мер против внедрения вредоносного ПО.

К категории среднего риска:

- 1) обучение НС на основании только достоверных данных;
- 2) неавторизованные связи НС должны быть блокированы.

И хотя статья [63] ориентирована прежде всего на БЭС, есть все основания полагать, что приведенное категорирование НС в части безопасности распространимо и на обычные суда.

Пример использования НС для защиты инфраструктуры морских объектов приведен в статье [65], где рассматривается парирование угроз в отношении операционных технологий, построенных на унифицированной для кораблей и подводных лодок Великобритании интегрированной системе управления платформой (Integrated Platform Management System – IPMS). Решение этой задачи базируется на применении мультиагентного обучения с подкреплением (Multi-Agent Reinforcement Learning’s – MARL) и среды моделирования IPMSRL.

Архитектура IPMS содержит удаленные терминалы, программируемые логические контроллеры и многофункциональные консоли управления, обеспечивающие интерфейс «человек–машина» и объединенные дублированной сетевой магистралью. В случае кибератаки IPMS выдает оповещение, передаваемое в систему управления информацией и событиями безопасности (Security Information and Event Management), которая инициирует стандартный процесс обработки киберинцидентов и реагирова-

ния на них в соответствии с требованиями NIST SP-800-61 Национального института стандартов и технологий (National Institute of Standards and Technology) США.

Согласно этим предписаниям необходимо последовательно сдерживать (contain) атаку, чтобы избежать ее распространения по системам, искоренить (eradicate) ее, чтобы удалить из зараженной системы и восстановить (recover) пораженный узел, а затем вернуть систему в рабочее состояние. Каждое из этих действий должно иметь настраиваемую задержку, где временной лаг определяется в зависимости от степени заражения узла и типа действия.

В статье тестируются два алгоритма MARL – IPPO [66] и MAPPO [67], устойчивые на этапе обучения и продемонстрировавшие возможность восстанавливать зараженную НС в IPMSRL. При этом MAPPO превзошел IPPO. Если с помощью MAPPO решалась задача восстановления с вероятностью 0,966 после 800 000 шагов, то IPPO на это требовалось 1 000 000 шагов.

Возвращаясь к вопросу кибербезопасности БЭС, нельзя обойти вниманием статью [68], где отмечается, что переход к автономным судам, отличающимся сложными системами связи и обработки данных, породил и своеобразные проблемы борьбы с киберугрозами.

Конгломерат последних в целом характеризуется, согласно [69], «спуфингом, фальсификацией, непризнанием, раскрытием информации, отказом в обслуживании и повышением привилегий». Здесь «фальсификация» – это изменение данных или нарушение работы диска, сети или памяти системы. «Непризнание» – отрицание факта получения или отправления сообщения. «Раскрытие информации» – передача конфиденциальной информации пользователям, которым она не должна быть доступна. «Отказ в обслуживании» – нарушение доступности системы, при котором нельзя загрузить все ресурсы, необходимые системе для правильной работы. «Повышение привилегий» – нарушение правил доступа, в результате чего злоумышленник получает возможность выполнять несанкционированные действия.

Авторы [68] в качестве первого по значимости ИИ-средства для борьбы с киберугрозами применительно к БЭС приводят блокчейн. В его основе лежит децентрализованная база данных, предназначенная для хранения сведений в виде отдельных элементов с набором характеристик, таких как дата создания, версия, информация о предыдущих действиях. Технология блокчейн с присущими ей свойствами прозрачности и устойчивости к несанкционированному доступу предлагает новый подход к безопасному ведению учета и коммуникации в морских операциях.

Важнейшим элементом кибербезопасности БЭС, считают авторы статьи, является и использование ГО, позволяющего заранее обнаружить киберугрозы и парировать их в реальном масштабе времени, что обеспечивает защиту от кибератак.

Учитывая, что целенаправленная борьба с киберугрозами была инициирована лишь в 2021 г., очевидно – поиск требуемых ИИ-технологий будет продолжен.

Заключение

Анализируя приведенные ранее примеры привлечения НС-технологий, можно отметить следующее.

1. Все возрастающий интерес к применению методов ИИ в навигации привел к росту числа публикаций, посвященных их использованию и в судовождении.

2. Результаты обзора выделенных нами путей решения задач в обеспечение судовождения свидетельствуют о том, что лишь при обнаружении и классификации судов и их расхождении сформировались устойчивые подходы к реализации соответствующих процессов. В первом случае по большей части задействуются НС CNN-типа, во втором – DRL-процедуры.

Порождено это с очевидностью близостью задач обнаружения и классификации судов, где НС-технологии находятся в стадии становления, и распознавания образов с помощью технического зрения, где CNN применяются не первое десятилетие. Аналогичное сходство имеют решения задач расхождения судов и управления подвижными объектами, например роботами, также базирующиеся на DRL-алгоритмах [75].

3. Нельзя не отметить, что в тех редких случаях, когда качество работы НС оценивалось путем сопоставления с результатами, полученными посредством калмановского фильтра того или иного вида, второй всегда оказывался в проигрыше. Последнее, на наш взгляд, скорее говорит о квалификации авторов статей, несомненно владеющих НС-технологиями, но испытывающих проблемы при адекватной постановке задачи калмановской фильтрации.

4. Если говорить о НС в целом, представляется, что нам еще предстоит определить область их применения в технических приложениях, где они дают существенный выигрыш по сравнению с традиционными подходами. Так, нельзя не отметить, что в рассмотренной нами задаче комплексирования ИНС/ГНСС, где модели всех процессов тщательно изучаются уже несколько десятилетий, существующая алгоритмика, не привлекающая ИИ-идей, в большинстве своем полностью удовлетворяет потребителей. Вместе с тем нельзя не отметить, что приведенные в обзоре примеры с очевидностью продемонстрировали работоспособность НС-процедур.

Благодарности

Работа выполнена при финансовой поддержке Санкт-Петербургского государственного университета, проект №116636233.

Список сокращений и обозначений

AI – Artificial Intelligence – искусственный интеллект
APF – Artificial Potential Field – искусственное потенциальное поле
Bi-LSTM – двунаправленная LSTM
BP – Backpropagation – метод обратного распространения ошибки
CNN – Convolutional Neural Network – сверточная нейронная сеть
COLREGs – Convention on the International Regulations for Preventing Collisions at Sea – Международные правила предупреждения столкновений судов в море
CPA – Closest Point of Approach – точка кратчайшего сближения
CSP – Central-point-based Ship Predictor – детектор на основе центральной точки
CTDE – Centralized Training Decentralized Execution – централизованное обучение децентрализованному исполнению
DRL – Deep Reinforcement Learning – глубокое обучение с подкреплением
EKF – Extended Kalman Filter – расширенный фильтр Калмана
ELM – Extreme Learning Machine – экстремальное машинное обучение

GRU – Gated Recurrent Unit – нейронная сеть на управляемых рекуррентных блоках
IPMS – Integrated Platform Management System – интегрированная система управления платформой

LLM – Large Language Model – большая языковая модель

LSTM – Long Short-Term Memory – длинная цепь с элементами краткосрочной памяти

MARL – Multi-Agent Reinforcement Learning’s – мультиагентное обучение с подкреплением

MLP – Multilayer Perceptron – многослойный перцептрон

NAR – Nonlinear Auto-Regressive – нелинейная авторегрессионная нейронная сеть

OZT – Obstacle Zone by Target – зона помехи, определяемая целью

ReLU – Rectified Linear Unit – выпрямленная функция линейной активации

RL – Reinforcement Learning – обучение с подкреплением

RNN – Recurrent Neural Network – нейронная сеть рекуррентного типа

Sec2Sec – Sequence to Sequence – нейронная сеть типа «последовательность в последовательность»

TCPA – Time for Closest Point of Approach – время движения до кратчайшей точки сближения

Transformer – нейронная сеть типа «Трансформер»

YOLO – You Only Look Once – нейронная сеть «Вы смотрите только раз»

АИС – автоматическая идентификационная система

АМО – ансамблевое машинное обучение

БЭС – безэкипажное судно

ГНСС – глобальная навигационная спутниковая система

ГО – глубокое обучение

ИИ – искусственный интеллект

ИНС – инерциальная навигационная система

ЛР – линейная регрессия

МО – машинное обучение

МП – многослойный перцептрон

НС – нейронная сеть

ПО – программное обеспечение

ПСС – предупреждение столкновений судов

РБФ – радиальная базисная функция

САН – система автономной навигации

СКП – среднеквадратическая погрешность

ССО – система ситуационной осведомленности

ФК – фильтр Калмана

ЛИТЕРАТУРА

1. Аль Битар Н., Гаврилов А. И., Халаф В. Методы на основе искусственного интеллекта для повышения точности интегрированной навигационной системы при отсутствии сигнала ГНСС. Аналитический обзор // Гирокоспия и навигация. 2019. №4. С. 3–28.
2. **Revolutionizing maritime safety** with artificial intelligence (AI), *Robotic Biz. Editorial*, 2003, September 12.
3. **Chen, X. et al.**, Application of Artificial Intelligence in Maritime Transportation, *Journal of Marine Science and Engineering*, 2024, no. 12.

4. Roy, G., Securing Shipping Lanes Through the Use of Artificial Intelligence, *Securities.io*, 2023, November 27.
5. Ривкин Б.С. Беспилотные суда. Навигация и не только // Гироскопия и навигация. 2021. №1. С. 111–132.
6. Murray, B. et al., Approvable AI for Autonomous Ships: Challenges and Possible Solutions, *Proceedings of the 32nd European Safety and Reliability Conference*, 2022, doi: 10.3850/978-18-5183-4_S05-01-186-cd.
7. Родионов А.Г. и др. Искусственный интеллект в судовождении – игра в имитацию? // Морской вестник. 2022. №4. С. 95–102.
8. Lee, E. et al., An Efficient Feature Augmentation and LSTM-Based Method to Predict Maritime Traffic Condition, *MDPI. Applied Science*, 2023, no. 13.
9. Li, Y. et al., Deep learning-powered vessel traffic flow prediction with spatial-temporal attributes and similarity grouping, *Engineering Applications of Artificial Intelligence*, 2023, no. 126, part B.
10. Rakthanmanon, T. et al., Searching and Mining Trillions of Time Series Subsequences under Dynamic Time Warping, *The 18th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, Beijing, China, 12–16 August, 2012, pp. 262–270.
11. Yoo, B., Kim, J., Path optimization for marine vehicles in ocean currents using reinforcement learning, *Journal of Marine Science and Technology*, 2016, vol. 2, pp. 334–343.
12. Пашенцев С.В. Решение навигационной задачи Цермело для произвольного осевого поля скоростей // Вестник МГТУ. 2010. № 3. С. 587–591.
13. Guo, S. et al., An Autonomous Path Planning Model for Unmanned Ships Based on Deep Reinforcement Learning, *Sensors*, 2020, no. 20.
14. Lillicrap, T.P. et al., Continuous control with deep reinforcement learning, *Computer Science*, 2015, no. 8.
15. Zhu, Z. et al., Automatic collision avoidance algorithm based on route – plan-guided artificial potential field method, *Ocean Engineering*, 2023, vol. 271.
16. Hai Zhou et al., Ship trajectory prediction based on BP Neural Network, *Journal on Artificial Intelligence*, 2019, no. 1, pp. 29–36.
17. Yongfeng Suo et al., A Ship Trajectory Prediction Framework Based on a Recurrent Neural Network, *Sensors*, 2020, no. 20, doi: 10.3390/s201185133.
18. Capobianco S. et al., Deep Learning Methods for Vessel Trajectory Prediction Based on Recurrent Neural Networks, *arXiv: 2101.02486*, 2021, vol. 2.
19. Wenxiong Wu, et al. Ship trajectory prediction: An Integrated Approach Using ConvLSTM – Based Sequence to Sequence Model, *Journal of Marine Science and Engineering*, 2023, no. 11.
20. Соснин А.С., Суслова И.А. Функции активации нейросети: сигмоида, линейная, ступенчатая, RELU, TANH // Наука. Информатизация. Технологии. Образование: материалы XII международной научно-практической конференции. Екатеринбург: Издательство РГППУ, 2019. С. 237–246.
21. Vaswani, A. et al., Attention Is All You Need, *Advances in Neural Information Processing Systems 30, Proceedings of the 31st Annual Conference on Neural Information Processing Systems (NIPS)*, 4–9 December 2017, Long Beach, CA, USA.
22. Dapeng Jiang et al., TRFM – LS: Transformer-Based Deep Learning Method for Vessel Trajectory Prediction, *Journal of Marine Science and Engineering*, 2023, no. 11.
23. Huanhuan Li et al., Deep Bi-directional information-empowered ship trajectory prediction for maritime autonomous surface ships, *Transportation Research. Part E*, 2024, 181.
24. Vapnik, V.N., The Support Vector method, *Artificial Neural Networks – ICANN’97, Lecture Notes in Computer Science*, 1997, vol. 1327, Springer, Berlin, Heidelberg, <https://doi.org/10.1007/BFb0020166>.
25. Aziz, K., Bouchara, F., Multimodal Deep Learning for Robust Recognizing Maritime Imagery in the Visible and Infrared Spectrums, *Image Analysis and Recognition. ICIAR 2018. Lecture Notes in Computer Science*, vol. 10882, Springer, Cham., https://doi.org/10.1007/978-3-319-93000-8_27.
26. Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S., Darrell, T., Caffe: convolutional architecture for fast feature embedding, *Proceedings of the 22nd ACM International Conference on Multimedia*, 2014, pp. 675–678.
27. Zhang, M.M., Choi, J., Daniilidis, K., Wolf, M.T., Kanan, C., VAIS: a dataset for recognizing maritime imagery in the visible and infrared spectrums, *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, June 2015, pp. 10–16.
28. Kwanghyum Kim et al., Probabilistic Ship Detection and Classification Using Deep Learning, *Applied Sciences*. 2018. no. 8. <https://doi.org/10.3390/app8060936>.

29. Ren, S. et al., Faster R-CNN: Towards real-time object detection with region proposal networks, *Advances in Neural Information Processing Systems*, Morgan Kaufmann: San Mateo, CA, USA, 2015, pp. 91–99.
30. Girshick, R., Fast R-CNN, *Proceedings of the IEEE 2015 Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 7–12 June 2015, pp. 1440–1448.
31. Redmon, J. et al., You Only Look Once: Unified, Real-Time Object Detection, *arXiv:1506.02640v5* [cs.CV], 9 May 2016.
32. Zhijian Huang et al., An Intelligent Ship Image/Video Detection and Classification Method with Improved Regressive Deep Convolutional Neural Network, *Complexity*, 2020, vol. 2020, issue 1, <https://doi.org/10.1155/2020/15208721>.
33. Fei Gao et al., Anchor-free Convolutional Network with Dense Attention Feature Aggregation for Ship Detection in SAR Images, *Remote Sensing*, 2020, no. 12, doi:10.3390/rs12162619.
34. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.-C., Mobilenetv2: Inverted residuals and linear bottlenecks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 18–22 June 2018, Salt Lake City, UT, USA, pp. 4510–4520.
35. Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S., Feature pyramid networks for object detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 21–26 July 2017, Honolulu, HI, USA, pp. 2117–2125.
36. Xian, S., Zhirui, W., Yuanrui, S., Wenhui, D., Yue, Z., Kun, F., Air-sar-ship-1.0: High resolution sar ship detection dataset, *J. Radars*, 2019, no. 8, pp. 852–862.
37. Hao Li et al., Enhanced YOLO v3 Tiny Network for Real-time Ship Detection from Visual Image, *IEEE Access*, 2021, vol. 9, pp. 16692–16706.
38. Liqiong Chen et al., Improved YOLOv3 Based on Attention Mechanism for Fast and Accurate Ship Detection in Optical Remote Sensing Images, *Remote Sensing*, 2021, no. 13.
39. Shao, Z. et al., SeaShips: A large-scale precisely annotated dataset for ship detection, *IEEE Transactions Multimedia*, 2018, vol. 20, no. 10, pp. 2593–2604.
40. Триполец О.Ю. Обзор существующих методов расхождения безэкипажных судов // Вестник Государственного университета морского и речного флота имени адмирала С.О.Макарова. 2021. Т. 13. №4.
41. Sawada, R. et al., Automatic ship collision avoidance using deep reinforcement learning with LSTM in continuous action space, *Journal of Marine Science and Technology*, 2020, 1–16, doi: 10.1007/s00773-020-00755-0.
42. Imazu, H., Evaluation method of collision risk by using true motion, *TransNav.*, 2017, vol. 11, no. 1, pp. 65–70.
43. Brockman, G. et al., Open AI gym., *arXiv: 1606.01540*, 2016.
44. Nomoto, K., Analysis of kempf's standard maneuver test and proposed steering quality indices, *Proceedings of the 1st symposium on ship manoeuvrability*, 1960, pp. 275–304.
45. Luman Zhao et al., Control method for path following and collision avoidance of autonomous ship based on deep reinforcement learning, *Journal of Marine Science and Technology*, 2019, vol. 27, no. 4, pp. 293–310.
46. Fossen, T.I., *Handbook of Marine Craft Hydrodynamics and Motion Control*, John Wiley and Sons Ltd., 2011.
47. Fossen, T.I. et al., Line-of-sight path following of underactuated marine craft, *Proceedings of the 6th IFAC Conference on Manoeuvring and Control of Marine Craft (MCMC 2003)*, pp. 211–216.
48. Вермишев Ю.Х. Основы управления ракетами. М.: Оборонгиз, 1968.
49. Schulman, J. et al., Proximal Policy Optimization, *arXiv: 1707.06347(cs)*, 2017.
50. Guan Wei, Wang Kuo, COLREGs – Compliant Multi-Ship Collision Avoidance Based on Multi-Agent Reinforcement Learning Technique, *Journal of Marine Science and Technology*, 2022, no. 10.
51. Alonso-Mora, J. et al., *Optimal Reciprocal Collision Avoidance for Multiple Non-Holonomic Robots*, Springer. Berlin/Heidelberg, Germany, 2013, pp. 203–216.
52. Oliehoek, F.A. et.al., Optimal and approximate q-value functions for decentralized POMDPs, *Artificial Intelligence Research*, 2008, no. 32, pp. 289–353.
53. Yihan Niu et al., A Multi-Ship Collision Avoidance Algorithm Using Data-Driven Multi-Agent Deep Reinforcement Learning, *Journal of Marine Science and Engineering*, 2023, no. 11.
54. Chen, C. et al., A Novel Ship Collision Avoidance Awareness Approach for Cooperating Ships Using Multi-Agend Deep Reinforcement Learning, *Journal of Marine Science and Engineering*, 2021, no. 9.

55. **Zhu, F. et al.**, Randomly Testing an Autonomous Collision Avoidance System with Real-World Ship Encounter Scenario from AIS Data, *Journal of Marine Science and Engineering*, 2022, no. 10.
56. **Liu, J.**, Collision Avoidance for Underactuated Ocean-Going Vessel Considering COLREGs Constraints., *IEEE Access*, 2021, no. 9.
57. **Hai-fa Dai et al.**, An INS/GNSS integrated navigation in GNSS denied environment using recurrent neural network, *Defence Technology*, 2020, no. 16, pp. 334–340.
58. **Mehdi Aslinezhad et al.**, ANN – assisted robust GPS/INS information fusion to bridge GPS outage, *EUROSIP Journal on Wireless Communications and Networking*, 2020, 129, <https://doi.org/10.1186/s13638-020-01747-9>.
59. **Chuang Zhang et al.**, Information Fusion Based on Artificial Intelligence Method for SINS/GPS Integrated Navigation of Marine Vessel, *Journal of Electrical Engineering & Technology*, 2020, no. 15, pp. 1345–1356.
60. **Li, J. et al.**, Improving positional accuracy of vehicular navigation system during GPS outages utilizing ensemble learning algorithm, *Information Fusion*, 2017, vol. 35, pp. 1–10.
61. **Taghizadeh, S., Safabakhsh, R.**, An integrated INS/GNSS system with an attention based hierarchical LSTM during GNSS outage, *GPS Solutions*, 2023, vol. 27.
62. **Gandhi, A., Sharma, A., Biswas, A., Deshmukh, O.**, Gethr-net: A generalized temporally hybrid recurrent neural network for multi-modal information fusion, *European Conference on Computer Vision*, Springer, Cham., Netherlands, Amsterdam, 2016, 8–16, pp. 883–899.
63. **Jiwoon Yoo and Yonghyun Yo**, Formulating Cybersecurity Requirements for Autonomous Ships Using the SQUARE Methodology, *Sensors*, 2023, no. 23.
64. **Ривкин Б.С.** Кибербезопасность на море. Навигационный аспект // Гирокоспия и навигация. 2023. №4. С. 167–191.
65. **Wilson, A. et al.**, Multi-Agent Reinforcement Learning for Maritime Operational Technology Cyber Security, *CAMLIS'23: Conference on Applied Machine Learning for Information Security*, October 19–20, 2023, Arlington, VA.
66. **de Witt, C.S. et al.**, Is Independent Learning All You Need in the StarCraft Multi-Agent Challenge?, *arXiv:2011.09533 [cs]*, 2020, URL: <http://arxiv.org/abs/2011.09533>.
67. **Yu, C. et al.**, The Surprising Effectiveness of PPO in Cooperative, Multi-Agent Games, *arXiv:2103.01955 [cs]*, 2022, URL: <http://arxiv.org/abs/2103.01955>.
68. **Nistor, A., Cezar, S.**, Marine Applications: The Future of Autonomous Maritime Transportation and Logistics, doi: 10.5772/intechopen.1004275.
69. **Shostack, A.**, *Threat Modeling: Designing for Security*, 1st edn, Wiley, Hoboken, 2014.
70. **Rumelhart, D.E., Hinton, G.E., Williams, R.J.**, Learning Internal Representations by Error Propagation, *Parallel Distributed Processing*, 1986, vol. 1, pp. 318–362.
71. **Zhao, X., et al.** A review of convolutional neural network in computer vision, *Artificial Intelligence Review*, 2024, vol. 57.
72. **Wang, X. et al.**, Deep Reinforcement Learning: A Survey, *IEEE Transactions on Neural Network and Learning Systems*, 2024, vol. 35, issue 4.
73. **Chiang, K.W. et al.**, Multisensor integration using neuron computing for land-vehicle navigation, *GPS Solutions*, 2003, vol. 6, no. 4, pp. 209–218.
74. **Sharaf, R. et al.**, Online INS/GPS integration with a radial basis function neural network, *IEEE Aerospace Electronic System Magazine*, 2005, vol. 20, no. 3, pp. 8–14.
75. **Liu, O.**, Deep Reinforcement Learning for Motion Control Algorithms in Robotic, *Transactions on Computer Science and Systems Research*, 2024, vol. 5.
76. **Klinsmann, A. et al.**, Large Language Model-based Decision-making for COLREGs and the Control of Autonomous Surface Vehicles, *arXiv:2411.16587v2 [cs.RO]*, 27 Nov. 2024.
77. **Sarhadi, P., Naeem, W., and Athanasopoulos, N.**, An integrated risk assessment and collision avoidance methodology for an autonomous catamaran with fuzzy weighting functions, *UKACC 13th International Conference on Control (CONTROL)*, 2022, pp. 228–234.
78. **Qiang Zhu et al.**, YOLOv7-CSAW for maritime target detection, *Front. Neurorobot*, 2023, vol. 17, <https://doi.org/10.3389/Fnbot.2023.1210470>.
79. **Степанов О.А.** Нейросетевые алгоритмы в задаче нелинейного оценивания. Взаимосвязь с байесовским подходом // Материалы докладов XI конференции молодых ученых «Навигация и управление движением». Санкт-Петербург, 2009. С. 39–65.
80. **Stepanov, O.A. et al.**, Adaptive algorithms for vessel roll prediction based on the Bayesian approach, *30th Mediterranean Conference on Control and Automation (MED)*, 2022, pp. 713–718.

Kuznetsov, N.V. (St. Petersburg State University) and **Rivkin, B.S.** (Concern CSRI Elektropribor, JSC, St. Petersburg)

Neural Networks in Ship Navigation, *Giroskopiya i Navigatsiya*, 2025, vol. 33, no. 1 (128), pp. 3–35.

Abstract. The paper presents an overview of neural network (NN) technologies applied in navigation support of marine surface vehicles. It considers the problems related to motion path generation, detection, classification, and avoiding collisions with approaching ships, as well as navigation data integration and cybersecurity issues.

Key words: artificial intelligence, navigation security, neural network, maritime autonomous surface ships, path, detection, awareness, classification, collision avoidance, integration, cybersecurity.

Материал поступил 31.10.2024