



Статья

VEPO-S2S: Прогнозирование траектории судна с портретной ориентацией
Модель на основе S2S FrameworkСиньй Ян 1,2,3,†, Чжунхэ Хань 1,3,4,5,†, Юаньбэнь Чжан 1,3,4,5, Ху Лю 2,*[‡], Сие Лю 1,3,4,5, Ваньчжэн Ай и Цзюньи Лю 1,3,4,5¹ Научно-исследовательский институт аэрокосмической информации Китайской академии наук, Пекин 100190, Китай; yxy915200@163.com (XY); hanzh@aircas.ac.cn (ZH); zhangyb@aircas.ac.cn (YZ); 18010076513@163.com (SL); liujy004735@aircas.ac.cn (JL)² Школа военно-морской архитектуры и морского судоходства, Чжэцзянский океанический университет, Чжоушю 361022, Китай; aiwanzheng@126.com³ Основная лаборатория технологий сетевых информационных систем, Институт электроники Китайской академии наук, Пекин 100190, Китай
Основная лаборатория целевого⁴ познания и прикладных технологий (ТСАТ), Пекин 100190, Китай 5 Школа электроники, электротехники и связи Инженерное дело, Университет Китайской академии наук, Пекин 100190, Китай

* Переписка: liuhu@zjou.edu.cn Эти авторы

† внесли равный вклад в эту работу.

Аннотация: Прогнозирование траекторий судов играет решающую роль в обеспечении безопасности на море и снижении количества морских аварий. Существенный прогресс был достигнут в задачах прогнозирования траекторий за счет применения методов моделирования последовательностей, включающих рекуррентные нейронные сети (RNN) и сети последовательностей (Seq2Seq). Однако (1) большинство этих исследований сосредоточено на применении информации о траектории, такой как долгота, широта, курс и скорость, игнорируя при этом влияние различных характеристик судна и поведенческих предпочтений на траектории. (2) Остаются проблемы с приобретением этих функций и предпочтений, а также с предоставлением модели возможности разумно интегрировать и эффективно выражать их. Чтобы решить эту проблему, мы представляем новую глубокую структуру VEPO-S2S, состоящую из многоуровневого модуля представления траектории судна (Multi-Rep) и модуля объединения и декодирования функций (FFDM). Помимо информации о траектории, мы сначала определили многоуровневые характеристики судна в Multi-Rep, включая атрибуты мелкого уровня (длина судна, ширина, осадка и т. д.) и функции глубокого уровня (предпочтение места плавания, предпочтение времени рейса, и т. д.). Впоследствии Multi-Rep был разработан для получения информации о траектории и многоуровневых характеристик судна с применением различных кодировщиков для кодирования. Затем FFDM выбрал и интегрировал вышеупомянутые функции из Multi-Rep для прогнозирования, используя как априорные, так и апостериорные механизмы, компонент Feature Fusion и расширенный декодер. Это позволяет модели эффективно использовать их и повышать общую производительность. Наконец, мы провели сравнительные эксперименты с несколькими базовыми моделями. Результаты экспериментов показывают, что ВЭПО-С2С количественно и качественно превосходит модели.

Ключевые слова: глубокое обучение; прогнозирование траектории судна; сеть «последовательность-последовательность»; морские происшествия; оценка риска; портрет судна



Цитирование: Ян, Х.; Хан, З.; Чжан, Ю.;

Лю, Х.; Лю, С.; Ай, В.; Лю, Дж.

ВЭПО-С2С: Портрет судна

Модель ориентированного прогнозирования траектории на основе S2S Framework.

Прил. наук. 2024, 14, 6344.

<https://doi.org/10.3390/app14146344>.

Научный редактор: Фивос Милонас, Катя Лида Кермандис и Манолис Марагудакис

Поступило: 3 июня 2024 г.

Пересмотрено: 13 июля 2024 г.

Принято: 16 июля 2024 г.

Опубликовано: 20 июля 2024 г.



Копирайт: © 2024 авторов.

Лицензиат MDPI, Базель, Швейцария.

Эта статья находится в открытом доступе. распространяется на условиях и условия Creative Commons

Лицензия с указанием авторства (CC BY)

(<https://creativecommons.org/licenses/by/4.0/>).

1. Введение

Судоходная отрасль стала более важной в мировой экономике, на ее долю в последние десятилетия приходится более 90% мировых грузоперевозок [1]. Следовательно, обеспечение безопасности на море и повышение эффективности мореплавания стали еще более актуальными. Использование системы автоматической идентификации (АИС) для прогнозирования траектории судов может предотвратить столкновения и обеспечить оценку рисков для регулирующих органов. В частности, эта задача включает в себя прогнозирование будущих путей на основе исторических точек траектории. Некоторые алгоритмы [2,3], такие как фильтр Калмана и машины опорных векторов, позволяют делать относительно точные прогнозы. Од

модели часто ограничены упрощениями и демонстрируют посредственную производительность в более сложных ситуациях [4].

Сегодня глубокое обучение достигло значительного прогресса и нашло широкое применение в самых разных областях. Рекуррентные нейронные сети (RNN), как модели прогнозирования временных рядов, широко применяются для прогнозирования траекторий, но они страдают от таких проблем, как исчезновение и взрыв градиента. В последние годы исследователи последовательно совершенствовали подходы к прогнозированию траекторий на основе RNN и добились заслуживающих внимания результатов. Авторы [5,6] предложили модель на основе GRU для фиксации временной динамики последовательностей траекторий. Эта модель может изучать нелинейные и сложные взаимосвязи между входными и выходными данными, кодируя исторические модели движения судов. Авторы [7] предложили модель траектории, основанную на долговременной памяти (LSTM), которая изучает модели движения судна на основе текущей среды и времени. Авторы [8] предложили метод прогнозирования траектории, сочетающий двунаправленную длинную краткосрочную память (BiLSTM) и пространственную кластеризацию приложений с шумом на основе плотности (DBSCAN). Этот метод объединяет модели траектории судна, обнаруженные с помощью DBSCAN, для дальнейшего повышения. Авторы [9,10] попытались включить механизмы внимания для захвата важной информации. Однако эти методы могут последовательно прогнозировать только одну точку, что приводит к быстрому накоплению ошибок при многоэтапном прогнозировании. Появление моделей Seq2Seq значительно облегчило эту проблему. Seq2Seq — это тип нейронной сети кодировщика-декодера, который изначально использовался в области машинного перевода и широко применялся для прогнозирования траектории. Он поддерживает многоточечный вывод за одну итерацию, эффективно уменьшая накопление ошибок. Авторы [11] разработали модель на основе ConvLSTM и Seq2Seq, расширяющую возможности улавливания глобальных временных зависимостей. Авторы работы [12] разделили акваторию моря с помощью пространственной сетки на основе модели Seq2Seq и добились хороших результатов в долгосрочном прогнозировании. Авторы работы [13] предложили модель METO-S2S, в которой используется многосемантический декодер, учитывающий влияние различных семантических данных корабля на прогнозирование траектории. В дополнение к методам, основанным на RNN, которые используют временную информацию, другой изученный подход предполагает использование пространственной информации для моделирования, при этом сверточные сети графов (GCN) являются наиболее репрезентативными. Чтобы решить проблему пространственно-временных зависимостей, [14] объединили k-GCN с LSTM, используя GCN для фиксации пространственных корреляций между узлами и LSTM для обработки пространственно-временных корреляций узлов, что позволяет прогнозировать скорость судов. Авторы [15] представили модель DAA-SGCN, используя ST-GCN для извлечения пространственных особенностей социального взаимодействия и RT-CNN для извлечения временных характеристик, полностью учитывая социальные взаимодействия между судами. Авторы работы [16] учитывали не только собственные намерения судна, но и влияние статической среды и окружающих динамически взаимодействующих агентов. Это исследование в основном было сосредоточено на применении информации о траекториях для прогнозирования и достигло примечательных результатов. Однако из-за сложных зависимостей в исторической информации и сильного влияния пространственных корреляций, полагаясь только на информацию о траектории, трудно достичь точных прогнозных результатов. Более того, многоуровневые характеристики судна, такие как атрибуты судна и предпочтения места плавания, также играют решающую роль в прогнозировании траектории. Согласно стандартам маневренности корабля [17], курсовая устойчивость и поворачиваемость являются важнейшими показателями маневренности, зависящими от коэффициента полноты, который определяется характеристиками судна. Изменения характеристик судна существенно влияют на маневренность, тем самым влияя на решения относительно портов, фарватеров и маршрутов. Кроме того, предпочтения местоположения плавания показывают их склонность к конкретным морским районам, которым следует уделять больше внимания в прогнозах. Как показано на рисунке 1, два типа судов демонстрируют различные траектории движения. По сравнению с траулерами грузовые суда обычно имеют больший объем и более высокий коэффициент блокировки, что приводит к большему радиусу поворота и худшей курсовой устойчивости. Чтобы снизить потенциальные риски, грузовые суда, как правило, выбирают более широкие морские пути и фарватеры, строго придерживаясь установленных графиков, чтобы обеспечить пунктуальную доставку грузов и повысить общую логистическую эффективность, что приводит к более плавным и регулярным траекториям.

и соответствующую нормативную политику, что часто приводит к нерегулярным и концентрированным маршрутам навигации. Поэтому крайне важно исследовать модели поведения различных судов и проводить индивидуальный прогнозный анализ на основе характеристик судов и районов эксплуатации.




Рисунок 1. Примеры траекторий для различных типов судов иллюстрируют существенные различия в траекториях навигации под влиянием различных характеристик и типов судов.

По этой причине по-прежнему сохраняются проблемы получения более полных характеристик, а также их целесообразного выбора и реализации. Вдохновленные персонажами пользователей [18], мы включили атрибуты мелкого уровня и функции глубокого уровня, определяя многоуровневые характеристики судна для создания комплексного портрета судна. Учитывая вышеупомянутые проблемы, мы предлагаем модель прогнозирования траектории судна VEPO-S2S, основанную на архитектуре Seq2Seq, включающую модуль многоуровневого представления траектории судна (Multi-Rep) и модуль объединения и декодирования функций (FFDM). Multi-Rep выполняет функцию получения и выражения функций и состоит из двух компонентов: компонента получения функций и компонента выражения функций. В компоненте сбора данных мы сначала указываем информацию о траектории, которая включает долготу, широту, скорость, курс и расстояние плавания. Затем определяются многоуровневые характеристики судна, охватывающие атрибуты мелкого уровня (такие как длина, ширина, осадка и т. д.), а также функции глубокого уровня (предпочтение места плавания, предпочтение времени рейса и т. д.). Все они получают через компонент сбора функций, а затем кодируются отдельно с помощью трех независимых кодировщиков в компоненте выражения функций.

Кроме того, несмотря на включение в модель информации о траектории и характеристик судна, базовые модели Seq2Seq сталкиваются с проблемами при их распознавании и эффективном использовании. Поэтому крайне важно выбрать и объединить информацию о траектории и характеристиках судна перед их применением. Для достижения этой цели мы предлагаем модуль FFDM, который состоит из компонента выбора портрета, компонента объединения функций и компонента многоголовочного декодирования. Сначала компонент выбора портрета определяет наиболее важные характеристики судна для текущей среды прогнозирования посредством анализа закодированных характеристик. Затем компонент Feature Fusion предназначен для объединения информации о траектории из модуля Multi-Rep с соответствующими характеристиками судна. Наконец, выходные данные служат входными данными для компонента многоголовочного декодирования, который разработан на основе традиционного декодера Seq2Seq. Компонент многоголовочного декодирования состоит из двух отдельных блоков GRU, каждый из которых контролирует долю информации о траектории и характеристиках судна во время прогнозирования, обеспечивая более точные выходные результаты.

Подводя итог, основные положения этой статьи можно резюмировать следующим

образом: • Мы предлагаем систему прогнозирования траектории судна VEPO-S2S, которая включает в себя модуль многоуровневого представления траектории судна (Multi-Rep) и модуль объединения и декодирования функций (FFDM). Эта структура полностью учитывает траект

информацию и характеристики судов, обеспечивая их разумную интеграцию и эффективное выражение для достижения более точных результатов.

- Мы предлагаем модуль Multi-Rep, который объединяет информацию о траектории с многоуровневыми характеристиками судна и использует несколько кодировщиков для кодирования. Этот модуль имеет возможность захватывать временные представления траекторий, а также подробный портрет судов.
- Чтобы решить проблему эффективного объединения и представления множества характеристик в нашей модели, мы предлагаем FFDM. Этот модуль выбирает и интегрирует характеристики, используя априорные и апостериорные механизмы, компонент Feature Fusion и расширенный декодер. FFDM может лучше представить пространственно-временную корреляцию между историческими траекториями.
- Мы провели сравнительные эксперименты на нескольких базовых моделях. Результаты экспериментов показали, что VEPO-S2S превзошел другие базовые модели как в количественном, так и в качественном аспектах, давая более надежные и точные результаты прогнозирования <https://github.com/AIR-SkyForecast/AIR-SkyForecast-VEPO-S2S/new/основной> (по состоянию на 15 июля 2024 г.).

2. Сопутствующие работы

2.1. Прогнозирование траектории судна

Традиционные методы прогнозирования траектории дали положительные результаты при прогнозировании траекторий транспортных средств, кораблей и пешеходов. Авторы [19] предложили метод инерциальной навигации с динамическим сопровождением для оценки наблюдаемых значений. Авторы [20] представили основанный на математическом моделировании метод фильтрации Калмана для слежения за поверхностью на больших расстояниях, позволяющий напрямую прогнозировать положение и курс цели без необходимости преобразования системы координат. Для повышения точности прогнозирования движения судна в условиях возмущений окружающей среды см. B [21] предложен алгоритм распознавания движения судна, основанный на методе наименьших квадратов. Однако эти методы продемонстрировали ограниченную точность прогнозирования в сложных ситуациях.

В последние годы разработка методов глубокого обучения для прогнозирования траектории судов быстро прогрессировала, и в этой задаче были достигнуты значительные успехи. В большинстве исследований используется структура RNN. Некоторые исследования основаны на LSTM [22] или GRU [6]. Кроме того, для исследования прогнозирования кораблей при различной плотности траектории см. [23] предложили модель, основанную на LSTM и K-ближайшем соседе (KNN). Авторы [24] представили модель MP-LSTM, которая объединяет сильные стороны TPNet и LSTM, устраняя недостатки существующих методов с точки зрения как точности, так и сложности модели.

Тем временем некоторые ученые пытались использовать архитектуру Seq2Seq для решения проблем прогнозирования. Авторы [25] представили модель нейронной сети, основанную на LSTM и Seq2Seq, используемую для фиксации долгосрочных зависимостей в исторических данных внутри траекторий. Авторы [26] предложили модель ST-Seq2Seq, основанную на архитектуре GRU. Авторы [27] предложили модель прогнозирования траектории на основе BiGRU и Seq2Seq, которая полностью учитывает взаимодействие между кораблями. Кроме того, было предложено несколько других моделей прогнозирования траектории. Авторы работы [13] представили модель METO-S2S на основе многосемантического декодера, учитывающую влияние различной семантической информации корабля на прогнозирование траектории. Они также использовали семантические векторы (SLV) для прогнозирования моделей в PESO [28], добившись выдающихся результатов на наборе данных AIS с открытым исходным кодом в США. В дополнение к модели Seq2Seq [29] применили структуру Transformer в сочетании с LSTM для захвата исторических траекторий во временных рядах и решения проблем, связанных с затуханием удаленной информации. Чтобы выразить взаимозависимость между кораблями, [30] предложили модель пространственно-временной мультиграфовой сверточной нейронной сети (STMGCN), которая моделирует как пространственно-временные данные, так и типы кораблей отдельно. Авторы [31] объединили свертку внимания графа (GAT) с расширенной структурой причинной свертки и разработали модель GAGW. Сеть свертки внимания графа отвечает за извлечение информации о взаимодействии между различными кораблями в космосе.

Большинство вышеупомянутых исследований в первую очередь сосредоточены на использовании информации о траекториях мелкого уровня. В этих исследованиях в качестве входных данных модели обычно используются скорость, курс и положение. Однако этого недостаточно для предотвращения уклонения корабля в сложной ситуации. Приобретение более богатых и глубоких характеристик, а также их разумное применение имеют решающее значение для управления уклонением от судов и общего планирования маршрута. Поэтому текущие исследования по прогнозированию траектории судов будут уделять больше внимания изучению многочисленных характеристик и пониманию динамики реальной среды.

2.2. Модель Seq2Seq

Модель Seq2Seq широко применяется в области машинного перевода [32] и состоит из кодера и декодера, где кодер встраивает входную информацию и генерирует многомерный семантический вектор, а декодер декодирует это и выводит результат. В основном мы представляем соответствующие исследования по задачам регрессии на основе Seq2Seq, включая прогнозирование мощности, прогнозирование стока и прогнозирование запасов.

В прогнозировании мощности см. [33] предложили модель Seq2Seq, основанную на LSTM, которая учитывает внутреннюю корреляцию данных, эффективно фиксируя последовательные отношения во временных рядах. Для решения проблемы низкой точности краткосрочных прогнозов температуры в [34] была предложена модель на основе Seq2Seq. В области прогнозирования стока см. [35] усовершенствовали Seq2Seq, заменив структуру RNN линейным слоем для обработки исторических данных. Кроме того, внедрение механизма внимания привело к более высокой точности прогнозирования. В [36] был представлен TEN-Seq2Seq для обработки табличных данных и глубины лунок, который показал лучшую надежность по сравнению с LSTM и FCNN. Авторы [37] предложили новый метод прогнозирования уровня резервуара с использованием LSTM и моделирования Seq2Seq на основе механизма внимания. Авторы [38] предложили структуру для прогнозирования цен на акции на основе сетей Seq2Seq.

Модель Seq2Seq также добилась значительного прогресса в области температуры поверхности моря (SST). Авторы [39] применили модель Seq2Seq с двухмодульным вниманием (TMA-Seq2Seq) для долгосрочного прогнозирования SST временных рядов, получив превосходящую производительность по сравнению с методами, управляемыми данными. В [40] была предложена новая сеть Seq2Seq для достижения прогнозирования на k шагов вперед на основе характеристик морских помех. Авторы [41] использовали модель Seq2Seq для пространственно-временного прогноза вероятности появления морского льда, что привело к более высокой точности.

2.3. Личности пользователей

Личности пользователей — это продукт развития Интернета, который позволяет обнаруживать различия между людьми внутри групп. Авторы [42] предложили модель личности пользователя-сотрудника, основанную на нейронных сетях, которая устанавливает персоны в соответствии с уровнем навыков и психическим состоянием сотрудников, что позволяет персонализировать рекомендации по работе для сотрудников предприятия. Авторы [43] предложили метод гибридных рекомендаций веб-сервисов на основе персонажей пользователей для решения проблемы холодного запуска для новых пользователей, улучшая как точность, так и качество рекомендаций.

В последнее время популярным направлением стало прогнозирование будущего поведения на основе профилей пользователей. Авторы [44] преобразовали характеристики эмоциональных предпочтений пользователей в информацию о внимании и объединили их с моделями LSTM для прогнозирования личностных качеств онлайн-пользователей. Авторы [45] предложили модель T-LSTM для прогнозирования занятости пользователей, преодолевающую проблемы с производительностью прогнозирования, которая предлагает новый и эффективный подход для точного прогнозирования занятости пользователей. Авторы [46] представили метод прогнозирования импульсивного вознаграждения у несовершеннолетних с использованием профилей пользователей, что позволяет точно прогнозировать импульсивное вознаграждение у несовершеннолетних пользователей. Авторы [47] применили персона-предсказание в области академических предупреждений для студентов вузов. Построение личности учащегося для изучения взаимосвязи между факторами учащегося и академической успеваемостью дает учителям и администраторам надежные рекомендации по корректировке планов обу

В этой работе мы создали профиль для каждого корабля и представили новую модель на основе Seq2Seq, которая на практике оказывается более подходящей для обнаружения столкновений и предупреждения о рисках.

3. Предлагаемый метод

Мы представляем метод в трех частях. Сначала дадим определения и постановку задачи. Далее мы даем подробный обзор обработки данных. Затем мы опишем подробный процесс построения портрета судна. Наконец, мы предоставляем подробное описание предлагаемой нами модели VEPO-S2S, включая модуль многоуровневого представления траектории судна и модуль объединения и декодирования функций.

4. Определения и постановка задачи.

Целью ВЭПО-С2С является прогнозирование будущей траектории судна на основе АИС-данные. Чтобы более четко сформулировать наш подход, мы даем следующие определения:

[Траектория судна] Точка траектории определяется как кортеж $x_t = (lon_t, lat_t, sog_t, cog_t, dist_t, l, w, d, t, \alpha, \beta, y)$ в момент времени t , в котором x_t состоит из долготы lon_t , широта lat_t , скорость курса cog_t , расстояние плавания $dist_t$, длина l , ширина w , осадка d , тип t , местоположение плавания sog_t , Предпочтение α , Предпочтение времени путешествия β и Предпочтение времени стоянки на якоре y соответственно. Траектория судна $X = (x_{t0}, x_{t1}, ..., x_{tn})$ определяется как хронологическая последовательность, где $\{t_i, i = 0, 1, 2, ..., n\}$ — набор временных меток.

[Последовательность позиций] Положение корабля в момент времени t определяется как кортеж $y_t = (lon_t, lat_t)$, а последовательность положений судна в момент времени $(1, 2, ..., t)$ определяется как $Y = (y_1, y_2, ..., y_t)$.

[Прогнозирование траектории судна] Учитывая наблюдаемую траекторию $X = (x_1, x_2, ..., x_t)$ в момент времени $(1, 2, 3, ..., t)$, цель состоит в том, чтобы спрогнозировать траекторию $Y = (y_{t+1}, y_{t+2}, ..., y_{t+k})$ в следующие временные метки $(t + 1, t + 2, ..., t + k)$.

4.1. Предварительная

обработка данных Предварительная обработка данных AIS необходима для обучения моделей глубокого обучения, особенно для моделей, которым требуется информация о траектории и характеристиках судна. В VEPO-S2S мы выбрали данные AIS из юго-западных и юго-восточных прибрежных вод США для обучения, проверки и тестирования. Набор данных включает статические атрибуты, такие как идентификатор морской мобильной службы (MMSI), длину и ширину судна. Кроме того, он включает в себя динамическую информацию о навигации судна, такую как долгота, широта, скорость и курс. Исходные данные AIS могут подвергаться неблагоприятным погодным условиям в процессе приема, что приводит к задержкам передачи сигнала и ошибкам приема [48]. Более того, на производительность моделей глубокого обучения может отрицательно повлиять потеря данных в результате технических проблем и обслуживания оборудования. Поэтому перед обучением мы провели комплексную предварительную обработку данных AIS (см. рисунок 2).




Рисунок 2. Процесс предварительной обработки данных.

Процесс представлен следующими этапами: (1)

Сортировка и классификация: мы отфильтровали суда с полной информацией о длине, ширине, осадке и типе, затем разделили данные о траектории каждого судна на основе идентификатора морской мобильной службы (MMSI).) номера и отсортировал их в порядке возрастания меток времени.

(2) Шумоподавление: мы удалили точки с повторяющимися метками времени и необоснованными долготой и широтой.

(3) Сегмент: мы разделяли траекторию на разные сегменты, когда временной интервал между двумя соседними точками траектории превышал 60 минут или когда расстояние между тремя последовательными точками траектории было менее 100 м.

(4) Интерполяция. Мы использовали кубическую сплайн-интерполяцию, чтобы обеспечить 10-минутный интервал между последовательными точками траектории.

(5) Вычисление: мы рассчитали курс и скорость для каждой точки траектории.

(6) Нормализация: мы нормализовали долготу, широту, скорость, курс, длину, ширину, и осадка с использованием метода нормализации мин-макс, как выражено в уравнении (1)

$$x_{\text{норм}} = \frac{x - x_{\text{мин}}}{x_{\text{макс}} - x_{\text{мин}}} \quad (1)$$

где x — исходные данные, $x_{\text{мин}}$ и $x_{\text{макс}}$ представляют минимальное и максимальное значение в данных траектории соответственно. $x_{\text{норм}}$ — нормализованные данные.

4.2. Портретная конструкция судна

В этой главе описывается построение портретов пользователей судна на основе данных АИС, включая создание системы этикеток и создание портретов судов.

4.2.1. Построение системы меток Как

показано на рисунке 3, мы создали систему меток, основанную на атрибутах поверхностного уровня и функциях глубокого уровня. Атрибуты мелкого уровня включали ряд фундаментальных атрибутов судна (таких как длина, ширина, осадка и тип). Эти характеристики существенно влияют на маневренность судов. Согласно стандартам маневренности корабля [17], как курсовая устойчивость, так и поворотливость являются важнейшими показателями маневренности и зависят от коэффициента блокировки корабля. Коэффициент полноты определяется как водоизмещение корабля, разделенное на произведение его длины, ширины и осадки. Более того, разные типы кораблей имеют разные коэффициенты полноты из-за различий в форме их подводных корпусов. Для судов одинакового водоизмещения суда с меньшими коэффициентами полноты (например, контейнеровозы) демонстрируют лучшую курсовую устойчивость, но меньшую поворачиваемость, чем суда с более высокими коэффициентами полноты (например, танкеры). Поэтому им требуются более широкие навигационные фарватеры, чтобы снизить риск столкновений с другими судами. Кроме того, эти характеристики (длина, ширина, осадка и тип) также играют решающую роль при выборе фарватеров, портов и маршрутов. Согласно руководствам по береговой инженерии [49], ширина фарватера обычно в два-пять раз превышает ширину судна. Суда должны учитывать как ширину, так и глубину при навигации, чтобы обеспечить безопасность и эффективность. При выборе порта, согласно PIANC [50], крупные суда должны выбирать порты с достаточным количеством причалов и пространством для маневрирования, чтобы обеспечить безопасную стоянку. При планировании маршрута суда должны учитывать радиус поворота и осадку, выбирая подходящие маршруты, чтобы избежать риска посадки на мель или столкновения. Следовательно, эти атрибуты имеют решающее значение для осуществимости и должны быть тщательно рассмотрены, чтобы обеспечить более точные прогнозы для различных судов.

Чтобы более эффективно моделировать информацию о траектории и многоуровневые характеристики судна, мы принимаем во внимание не только атрибуты мелкого уровня, но и функции глубокого уровня. Функции глубокого уровня определяются как предпочтение места плавания, предпочтение времени рейса и предпочтение времени стоянки на якоре. Предпочтение места плавания отражает модель поведения корабля. Например, контейнеровозы, занимающиеся линейными перевозками, обычно работают на фиксированных маршрутах и в пределах портовых зон для обработки и перевалки. Фиксированные маршруты и регулярные графики линейных перевозок обеспечивают своевременность логистики, снижение потерь и увеличение доходов. Между тем, траулеры в основном работают в определенных рыболовных районах [52], где их предпочтения в отношении места плавания зависят от распределения рыбных ресурсов. В отличие от линейного судоходства, траулеры имеют более гибкую схему навигации, часто корректируя места промысла в зависимости от сезона, чтобы соответствовать нормативным ограничениям и увеличить доходы. Это предпочтение обеспечивает более полноту

понимание поведения судна и повышает точность прогнозирования траектории. Что касается предпочтения времени рейса и предпочтения времени стоянки на якоре, контейнеровозы стремятся минимизировать время стоянки [53], строго придерживаясь графиков для оптимизации операционной эффективности. Такой режим работы не только обеспечивает своевременную транспортировку грузов, но и способствует снижению эксплуатационных расходов. Напротив, предпочтения времени рейса траулеров в большей степени зависят от правил управления рыболовством и требований рынка. Эта временная информация способствует более глубокому пониманию моделей поведения судов и позволяет моделям прогнозирования точно фиксировать колебания движения судов с течением времени.




Рисунок 3. Процесс моделирования и анализа на уровне метки.

4.2.2. Портретная конструкция судна

Портрет судна состоит из атрибутов мелкого уровня и функций глубокого уровня. Что касается обработки атрибутов мелкого уровня, мы используем следующий подход: сначала выбираем данные AIS с непустыми атрибутами (такими как длина, ширина, осадка и тип). Затем мы случайным образом выбираем 100 точек данных на основе идентификатора морской мобильной службы. Для каждого атрибута рассмотрим значение с самой высокой частотой в качестве текущего атрибута судна, чтобы построить профиль мелководья судна. Этот процесс можно выразить формулой :
Уравнение (2)

$$Y = \{y_i \mid y_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}, D_k \subseteq X, x_j \in p(x_j \mid D_k) \mid \max\} \tag{2}$$

где Y представляет атрибуты мелкого уровня всех судов, а каждый элемент y_i обозначает атрибуты i-го судна. D_k представляет коллекцию данных AIS с полными атрибутами, X обозначает набор атрибутов всех данных AIS, а каждый элемент x_j представляет значение самой высокой частоты для D_k .

После получения атрибутов мелкого уровня мы сосредоточились на процессе получения функций глубокого уровня, которые включают предпочтение места плавания, предпочтение времени путешествия и предпочтение времени стоянки на якоре. Для выбора местоположения плавания из-за разницы в количестве и распределении точек траектории корабля мы использовали HDBSCAN (иерархическая пространственная кластеризация приложений с шумом на основе плотности) [54] для кластерного анализа. Результаты кластеризации показаны на рисунке 4. Разные цвета представляют разные кластеры, а черные метки обозначают центры кластеризации. Между тем, чтобы отразить предпочтение времени путешествия и время стоянки на якоре, мы разделили день на 24 сегмента и присвоили точкам траектории каждого судна соответствующую метку. Распределение точек траектории в каждом периоде отражает временные предпочтения судов . После обработки профиль каждого судна можно выразить как уравнение (3)

$$S_{mmsi} = \{l_{mmsi}, w_{mmsi}, d_{mmsi}, t_{mmsi}, a_{mmsi}, b_{mmsi}, y_{mmsi}\} \tag{3}$$

где $lmmsi$, $wmmsi$, $dmmsi$ и $tmmsi$ соответственно представляют атрибуты мелкого уровня. длины, ширины, осадки и типа $ammsi$ представляет предпочтение времени рейса, $\beta mmsi$ означает предпочтение времени стоянки, а $\gamma mmsi$ — предпочтение места плавания. В то время как $ammsi$ и $\beta mmsi$ преобразуются в два 24-мерных объекта, $\gamma mmsi$ преобразуется в 114-мерный объект. Использование портрета судна подробно описано в Раздел 4.3.1.




Рисунок 4. Результат кластеризации траекторий. Разные цвета представляют разные кластеры, а черные метки указывают центры кластеров.

4.3. Модель ВЕПО-С2С

Мы предлагаем новую модель прогнозирования траектории VEPO-S2S, основанную на Seq2Seq модель, а структура показана на рисунке 5. Как видно из рисунка, ВЭПО-С2С состоит из модуля многоуровневого представления траекторий судов (Multi-Rep) и функции Модуль слияния и декодирования (FFDM). Multi-Rep предназначен для определения траектории информацию и многоуровневые характеристики судна, кодируя их несколькими кодировщиками. FFDM предназначен для отбора и объединения вышеуказанной информации и характеристик из Multi-Rep для прогнозирования.




Рисунок 5. Структура VEPO-S2S включает в себя многоуровневый модуль представления траектории судна (Multi-Rep) и модуль объединения и декодирования функций (FFDM). Multi-Rep разработан для получения информации о траектории и многоуровневых характеристиках судна с использованием отдельных кодировщиков для кодирования. FFDM предназначен для выбора и интеграции вышеуказанных характеристик из Multi-Rep для предсказания.

4.3.1. Модуль многоуровневого представления траектории движения судна

Модуль многоуровневого представления траектории судна предназначен для получения информации о траектории и многоуровневых характеристик судна и применения отдельных кодировщиков для кодирования. В этом подразделе мы представляем модуль многоуровневого представления траектории судна, который состоит из компонента получения признаков и компонента представления признаков. Для компонента сбора данных мы получили информацию о траектории и многоуровневые характеристики судна посредством предварительной обработки данных, как описано в разделе 4.1, и построения портрета судна, как описано в разделе 4.2. Одновременно, основываясь на моделях RNN и Seq2Seq, мы представили компонент представления функций, состоящий из трех отдельных кодеров. Эти кодеры предназначены для отдельной обработки различных входных характеристик компонента сбора данных. Кодер траектории отвечает за кодирование информации о траектории (включая долготу, широту, скорость, курс и расстояние навигации). Этот процесс можно выразить следующим уравнением (4)

$$\begin{aligned} X_{traj} &= (x_1, x_2, \dots, x_n) \quad n = \\ &= (lon_n, lat_n, sog_n, cog_n, dis_n) \end{aligned} \quad (4)$$

Ч, ч, ч = Энктрадж(Хтрадж)

где X_{traj} представляет информацию о траектории, включая нормализованную долготу, широту, скорость, курс и расстояние навигации для десяти точек траектории. $N = [h_1, h_2, \dots, h_{10}]$ обозначает скрытое состояние на каждом временном шаге, h^* обозначает скрытое состояние на последнем временном шаге, а h представляет окончательное скрытое состояние. Подобно кодировщику траектории, задача кодировщика меток Y_{label} состоит в том, чтобы закодировать золотую траекторию и вывести закодированное состояние Y_u , где Y_{label} представляет пять точек траектории, содержащие долготу и широту.

$$\begin{aligned} Y_{label} &= (x_{11}, x_{12}, \dots, x_{15}) \quad y_n \\ &= (lon_n, lat_n) \end{aligned} \quad (5)$$

$Y_u = \text{Enctraj}(Y_{label})$

Задача кодировщика портретных характеристик — внедрить многоуровневые характеристики судов.

тики в многомерный вектор. Сначала нормализованные непрерывные числовые значения (включая длину, ширину и осадку) были объединены и встроены в восьмимерный семантический вектор. Во-вторых, дискретный тип судна был преобразован в непрерывное значение для входных данных модели и индивидуально встроено в другой семантический вектор.

В-третьих, мы закодировали две 24-мерные функции глубокого уровня, чтобы зафиксировать предпочтение времени путешествия и предпочтение времени стоянки на якоре (как упоминалось в разделе 4.2.2), в то время как предпочтение места плавания было закодировано отдельно. Наконец, они были объединены в семимерный вектор признаков, который был введен в кодировщик портретных характеристик для кодирования. Этот процесс можно выразить следующим уравнением (6)

$$\begin{aligned} sp &= \text{concat}(l, w, d) \quad sp = \\ &= \text{embedsp}(sp) \quad \text{type} = \\ &= \text{embedtype}(\text{type}) \quad \text{tim} = \\ &= \text{concat}(\alpha, \beta) \quad \text{tim} = \\ &= \text{embedtim}(\text{tim}) \quad y = \\ &= \text{embedy}(y) \quad \text{por} = \\ &= \text{concat}(\text{Encpor}(sp, \text{тип}, \text{Тим}, y)) \end{aligned} \quad (6)$$

где por представляет объект портрета, а embedsp , embedtype , embedtim и embedy — слои внедрения. Encpor — это кодировщик портретных изображений. l , w и d обозначают длину, ширину и осадку соответственно, t — тип, α — предпочтение времени рейса,

β представляет собой предпочтительное время стоянки на якоре, а γ — предпочтительное место плавания (как указано в уравнении (3)).

4.3.2. Модуль слияния и декодирования функций

Несмотря на включение в модель информации о траектории и характеристиках судна, базовые модели Seq2Seq по-прежнему испытывают трудности с эффективным распознаванием и использованием. Поэтому модуль объединения и декодирования признаков был разработан для выбора и интеграции информации о траектории с многоуровневыми характеристиками судна, применяя априорные и апостериорные механизмы в компоненте выбора портрета, компоненте объединения признаков и многоголовочном декодере. Компонент. Целью компонента выбора портрета является определение и выбор подходящих многоуровневых характеристик судна для прогнозирования; следовательно, мы используем априорное распределение и апостериорное распределение вместе при выборе характеристик судна, и схема показана на рисунке 6. Априорное распределение выбирает характеристики на основе сходства между вектором h^* из кодера траектории и вектором портрета. por , который помогает отфильтровать наиболее важные характеристики на ранних стадиях модели, сокращая вычислительные затраты. Этот процесс можно выразить уравнением (7)

$$Z_{prior}(por = por_i | h^*) = \frac{\exp(por_i \cdot h^*)}{\sum_{j=1}^7 \exp(por_j \cdot h^*)}, \tag{7}$$

где por_i ($por_1, por_2, \dots, por_7$), — скалярное произведение, h^* — вектор кодирования траектории, а por — вектор портрета. В частности, модель присваивает более высокие веса векторам с большим сходством путем сравнения результатов скалярного произведения различных характеристик, уменьшая помехи избыточной информации и повышая эффективность вычислений.




Рисунок 6. Компонент выбора портрета состоит из предварительного и апостериорного распределения. Априорное распределение выражает вектор h кодирования траектории и характеристику портрета por , а апостериорное распределение включает метку y для повышения точности выбора. Между тем, KLD предназначен для устранения разрыва между априорным и апостериорным распределением, позволяя априорному распределению извлечь выгоду из апостериорного распределения и генерировать более точные результаты.

Однако опора только на априорное распределение не может позволить получить точные результаты, поскольку оно обычно основано на предположениях или исторических данных, которые не полностью отражают реальную ситуацию; следовательно, невозможно выбрать подходящие характеристики для управления генерацией. Напротив, характеристики, используемые в метке y , могут быть получены посредством апостериорного распределения. Следовательно, апостериорное распределение, полученное путем объединения траект

вектор h и метка y могут более эффективно определять выбор профиля, который можно выразить как

$$Z_{\text{post}}(\text{por} = \text{пор } i | h, y) = \frac{\exp(\text{por}_i \cdot \text{MLP}([h; y]))}{\sum_{j=1}^7 \exp(\text{por}_j \cdot \text{MLP}([h; y]))} \quad (8)$$

где MLP — линейный слой, $\cdot$ — скалярное произведение и $;$ представляет собой векторное сращивание.

В то же время существует значительный разрыв между априорным и апостериорным распределением. Чтобы решить эту проблему, используется потеря дивергенции Кульбака – Лейблера (KLD), чтобы обеспечить их близость. Он может эффективно исправлять ошибки в предыдущем распределении и направлять выбор профиля в пользу модели. Стабильность расхождения КЛД заключается в его математических свойствах, обеспечивающих сходимость и надежность. Минимизируя потери KLD, система может обеспечить подходящий баланс между априорным и апостериорным распределениями. Формула дивергенции КЛД выражается следующим образом:

$$D_{\text{KL}}(PQ) = \sum_{i \in \text{Вопрос (я)}} P(i) \log \frac{P(i)}{Q(i)} \quad (9)$$

где P представляет собой апостериорное распределение, которое включает в себя характеристики, необходимые под руководством реальных меток.

В общем, простой подход к использованию выбранных характеристик для генерации результатов заключается в непосредственном добавлении этих характеристик к входным данным кодировщика. Однако этот подход обычно не дает удовлетворительных результатов из-за отсутствия гибкости в контроле степени вовлечения характеристик. Поэтому мы вводим компонент Feature Fusion для оптимизации использования характеристик. По сравнению с прямым соединением этих характеристик мы использовали более гибкий способ их интеграции. Здесь мы применили LSTM для объединения априорного распределения и исторической траектории H , и результаты LSTM приняли во внимание непрерывность и корреляцию между характеристиками во времени. Кроме того, априорное состояние служило начальным скрытым состоянием LSTM, а представление траектории H , полученное кодировщиком траектории, использовалось в качестве входных данных на каждом этапе. Наконец, мы получили объединенный семантический вектор c , и этот процесс можно выразить с помощью следующего уравнения (10)

$$c_t^K = \text{LSTM}(\text{предыдущий}, H) \quad (10)$$

Чтобы регулировать участие многоуровневых характеристик судна в прогнозировании, мы ввели компонент многоголового декодирования; схема структуры изображена на рисунке 7. Этот компонент состоит из двух блоков GRU и блока объединения, который эффективно синтезирует скрытые состояния, генерируемые двумя блоками GRU, для прогнозирования будущих траекторий.

Проект разработан таким образом, чтобы корректировать соотношение между информацией о траектории и характеристиками судна в процессе прогнозирования. Оранжевая область — это стандартный модуль ГРУ, который получает информацию о траектории h . Кроме того, он принимает предыдущее значение прогнозирования y_{t-1} в качестве входных данных, создавая свое скрытое состояние T_{t-1}^H . Другой GRU предназначен для добавления в прогнозы предшествующего распределения пор; он также принимает объединенный семантический вектор t , информацию о траектории h и предыдущее значение прогнозирования y_{t-1} в качестве входных данных, генерируя p и T , которые объединяются через шлюз объединения, чтобы

представление признака T_{t-1}^H . В конечном итоге T_{t-1}^H определяет окончательную траекторию. Этот процесс можно выразить уравнением (11):

$$\begin{aligned} T_{t-1}^H &= \text{GRU}_n(y_{t-1}, h) \\ \text{inpp} &= \text{concat}(y_{t-1}, c_{t-1}^K, \text{ранее}) \\ T_{t-1}^H &= \text{GRU}_p(\text{inpp}, c_t) \\ O_t &= \sigma(W_z \cdot [\tanh(w_y \cdot T_{t-1}^H); \tanh(W_k \cdot T_{t-1}^H)]) \\ T_t &= O_t \cdot T_{t-1}^H + (1 - O_t) \cdot T_p \end{aligned} \quad (11)$$

где $i \in \{11, 12, \dots, 15\}$, а W_z , W_y и W_k соответствуют весовым матрицам с разными коэффициентами. σ и $\tanh$ — функция активации сигмовидной кишки и функция активации $\tanh$ соответственно.




Рисунок 7. Компонент многоголовочного декодера состоит из двух блоков GRU и блока слияния. Он может гибко регулировать соотношение между информацией о траектории и характеристиками судна в процессе прогнозирования.

4.3.3. Функция потерь

ВЕРО принимает среднеквадратическую ошибку (RMSE) и дивергенцию Кульбака-Лейблера (KLD) (как указано в уравнении (9)) в качестве функции потерь. Целью данной работы является использование первых m точек, обозначенных $X_k = (x_k^1, \dots, x_k^m)$, предсказать последующие n (x точек отслеживания, где m и n — гиперпараметры. Последовательность прогнозирования и $m+2, \dots$. Последовательность y_k представлена $Y_k = (y_k^1, \dots, y_k^{m+n})$, и y_k — цель $(y_k^{m+1}, \dots, y_k^{m+n})$, $m+1, \dots, y_{m+2}, \dots$, y соответственно. Основная цель — минимизировать функцию потерь во время обучения, обеспечивая большую точность прогнозирования последних n точек траектории. Выражение для функции потерь показано в следующем уравнении (12).

$$L = \frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2 + \text{ДКЛ} \quad (12)$$

5. Эксперименты

Чтобы проверить эффективность модели ВЕРО, мы провели серию количественных и качественных экспериментов. В частности, мы сначала представляем настройки эксперимента, включая настройки гиперпараметров, экспериментальную среду, наборы данных, базовые модели и оценочные показатели. Впоследствии мы представляем результаты количественного сравнения предложенного нами метода и других базовых моделей. После этого мы описываем эксперименты по абляции, проведенные для обоснования эффективности различных компонентов модели. Наконец, мы изобразим результаты прогнозирования ВЕРО-S2S посредством качественного анализа.

5.1. Настройки эксперимента

5.1.1. Набор данных

Мы приняли данные АИС (<https://marinecadastre.gov/accessais/>) (по состоянию на 1 июня 2024 г.) из прибрежных вод юго-востока и юго-запада США для обучения, проверки и тестирования [13]. Как показано в таблице 1, в этом наборе данных 68 типов судов и 28 645 судов. При этом, ввиду особенностей построения портрета (как указано в разделе 4.2.2), мы выбрали атрибуты судна (в том числе длину, ширину, осадку и тип). После обработки мы получили 45 типов, всего 6194.

сосуды. Подробное распределение типов судов показано на рисунке 8. В нашем наборе данных максимальное количество типов судов составляло 45, включая пассажирские суда, прогулочные суда, парусные суда и т. д. Распределение типов судов было неравномерным, и в основном они подразделялись на пять категорий: пассажирские суда, прогулочные суда, парусные суда, буксирно-буксирные и рыболовные суда. Пассажирские и прогулочные суда вместе составили более 23% от общего числа. Остальные суда, в основном состоящие из грузовых судов, контейнеровозов и танкеров, в совокупности составляют 21% набора данных. Чтобы повысить богатство и полноту данных, мы использовали подход скользящего окна, разделив нормализованные данные на группы 15 точек траектории с шагом скольжения 1 (см. рисунок 9). Впоследствии каждое судно было распределяется по наборам обучения, проверки и тестирования в соотношении 8:1:1. Этот подход увеличил разнообразие данных и обеспечить, чтобы каждое судно прошло достаточную проверку.

Таблица 1. Подробности нашего набора данных.

Набор данных	Область	Количество точек трека	Тип	Количество	Количество судов
Общий	Побережье США	144 445 580 4	68		28 645
Наше побережье США		930 061	45		6194




Рисунок 8. Распределение типов судов в нашем обработанном наборе данных.




Рисунок 9. Пример разделения набора данных методом скользящего окна, красные точки обозначают точки траектории.

5.1.2. Настройки гиперпараметров и экспериментальная среда

Мы использовали десять точек траектории в качестве входных данных для прогнозирования последних пяти точек траектории. и эти два гиперпараметра можно гибко настраивать для адаптации к различным задачам. Между тем , для обучения модели было установлено 40 эпох, а наилучшие показатели оценки был спасен. Скорость обучения составила 0,001 с затуханием веса 0,0, был установлен оптимизатор Адаму, а размер партии был установлен на 128. Более того, скрытые размеры в ГРУ были

установлено значение 64, а номер скрытого слоя равен 2. В приведенных выше гиперпараметрах мы выбрали два типичных случая для визуализации: количество слоев и скрытые размеры, детали которых показаны на рисунках 10 и 11. Эксперименты все они были основаны на Python 3.8 с использованием платформы PyTorch. Мы обучали модель, используя операционную систему Ubuntu и GTX 3090Ti на сервере для экспериментов.




Рисунок 10. Влияние различных слоев GRU на прогноз модели VEPO-S2S по данным RMSE. Ось X представляет количество слоев, а ось Y представляет значение потерь RMSE.




Рисунок 11. Влияние различных скрытых размеров на прогноз модели VEPO-S2S по данным RMSE. Ось X представляет количество скрытых размеров, а ось Y представляет значение потерь RMSE.

5.1.3. Базовые показатели

Чтобы лучше оценить производительность VEPO-S2S, мы сравнили его с несколькими базовыми моделями, использующими тот же набор данных. В отличие от Seq2Seq, рекуррентные нейронные сети ограничены прогнозированием нескольких последовательных точек трека. В наших экспериментах мы непрерывно прогнозировали пять точек траектории с помощью RNN, что было достигнуто с помощью метода скользящего окна. Исходные данные были следующими:

- (1) Калман: линейная оптимальная модель оценки;
- (2) VAR: статистическая модель для многомерного прогнозирования временных рядов;
- (3) ARIMA: статистическая модель прогнозирования временных рядов;
- (4) LSTM: тип рекуррентной нейронной сети, состоящей из двух слоев;
- (5) BiLSTM: аналогично LSTM, BiLSTM состоит из двух двунаправленных LSTM-слоев;
- (6) ГРУ: аналогично LSTM;
- (7) BiGRU: аналогичен GRU, но с двумя двунаправленными слоями GRU;
- (8) LSTM-LSTM: модель Seq2Seq с двухслойным LSTM в качестве кодера и декодера;

(9) BiLSTM-LSTM: модель Seq2Seq с двухслойным BiLSTM в качестве кодера и четырехуровневым LSTM в качестве декодера; (10) ГРУ-ГРУ: аналогично LSTM-LSTM; (11) БиГРУ-ГРУ: аналогично BiLSTM-LSTM; (12) Трансформатор: модель Seq2Seq, основанная на механизме внимания; (13) МЕТО-S2S: метод прогнозирования траектории судна на основе S2S с многосемантическим кодером и типоориентированным декодером.

5.1.4. Метрики оценки

Чтобы оценить эффективность прогнозирования предложенной модели, мы использовали четыре оценочных показателя, включая среднеквадратическую ошибку (RMSE), среднюю абсолютную ошибку (MAE), среднюю ошибку смещения (ADE) и окончательную ошибку смещения (FDE). RMSE фокусируется на измерении стабильности результата, а MAE оценивает прогнозирующую способность модели. ADE означает среднюю ошибку евклидова расстояния между прогнозируемым и фактическим положением. Кроме того, FDE уделяет особое внимание окончательной точности прогнозов.

$$\begin{aligned}
 \text{СКО} &= \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2} \\
 \text{МАЭ} &= \frac{1}{n} \sum_{k=1}^n |y_k - \hat{y}_k| \\
 \text{АДЕ} &= \frac{1}{n} \sum_{k=1}^n \|y_k - \hat{y}_k\|_2 \\
 \text{FDE} &= \|y_{\text{final}} - \hat{y}_{\text{final}}\|_2
 \end{aligned} \tag{13}$$

где y_k и $\hat{y}_k$ представляют собой истинное положение и предсказанное положение, n — общее количество предсказанных точек трека, а $\cdot$ и $\|\cdot\|_2$ обозначают одну норму и евклидово расстояние соответственно. y_{final} и $\hat{y}_{\text{final}}$ представляют конечное положение фактической траектории и прогнозируемой траектории соответственно. Стоит отметить, что чем ниже индекс оценки, тем лучше обобщающая способность модели.

5.2. Сравнение производительности

моделей 5.2.1. Результаты

сравнения. Благодаря сравнению с базовыми показателями с использованием показателей оценки RMSE, MAE и ADE, наша модель продемонстрировала высокую надежность, как показано в таблицах 2–4. LSTM, BiLSTM, GRU и BiGRU используют подход скользящего окна для прогнозирования нескольких точек, в то время как другие шесть моделей Seq2Seq этого не делают. Наша модель превзошла базовые линии в третьей-пятой точках траектории. Однако по первому и второму пунктам ГРУ добилось лучших результатов в МАЭ в таблице 3 и в АДЭ в таблице 4. Это происходит главным образом потому, что ГРУ имеет структурное преимущество в прогнозировании краткосрочных последовательностей благодаря своей простоте. Однако VEPO-S2S испытывает небольшое снижение при обработке краткосрочных прогнозов, поскольку портрет судна может быть не так легко различим. Согласно RMSE, MAE и ADE, когда длина прогноза увеличивается, наша модель работает лучше, чем базовые модели.

Одновременно, учитывая, что прогнозирование траектории также является проблемой прогнозирования временных рядов, мы сравнили VEPO-S2S с несколькими моделями прогнозирования временных рядов, включая ARIMA, фильтр Калмана и VAR. Как показывают таблицы 2–4, наша модель превосходила другие; Модели прогнозирования трех временных рядов хорошо зарекомендовали себя в краткосрочном прогнозировании, но точность быстро падала по мере увеличения горизонта прогнозирования. В частности, модель VAR стала неэффективной после третьего временного шага, поскольку она не смогла отразить долгосрочные сложные нелинейные взаимосвязи. В отличие от моделей временных рядов, которые используют только последовательности позиций, VEPO-S2S использует дополнительную предварительную информацию

и ширину, а также его мощную способность строить пространственно-временные корреляции на основе точки исторической траектории, что делает его более выгодным в задачах прогнозирования.

Таблица 2. Результаты сравнения VEPO-S2S с различными базовыми показателями по метрике оценки RMSE. Здесь 10->5 представляет собой значение RMSE последних 5 траекторий, предсказанных 10 историческими траекториями.

Название модели	10-> 1	10->2	10->3	10->4	10->5
Кальман	$2,42 \times 10^{-4}$	$3,00 \times 10^{-4}$	$4,22 \times 10^{-4}$	$2,80 \times 10^{-4}$	$5,51 \times 10^{-4}$
ВАР	$0,98 \times 10^{-4}$	10^{-4}	$50,43 \times 10^{-4}$	-	-
АРИМА	$3,42 \times 10^{-4}$	$5,30 \times 10^{-4}$	$7,21 \times 10^{-4}$	$9,15 \times 10^{-4}$	$1,16 \times 10^{-4}$
ЛСТМ	$0,88 \times 10^{-4}$	10^{-4}	$3,46 \times 10^{-4}$	$2,65 \times 10^{-4}$	$3,51 \times 10^{-4}$
БилСТМ	$2,64 \times 10^{-4}$	$1,58 \times 10^{-4}$	$2,41 \times 10^{-4}$	$3,32 \times 10^{-4}$	$3,24 \times 10^{-4}$
ГРУ	$0,86 \times 10^{-4}$	10^{-4}	$4,71 \times 10^{-4}$	$1,94 \times 10^{-4}$	$2,76 \times 10^{-4}$
БиГРУ	$3,16 \times 10^{-4}$	$2,21 \times 10^{-4}$	$3,07 \times 10^{-4}$	$3,99 \times 10^{-4}$	$1,69 \times 10^{-4}$
ЛСТМ-ЛСТМ	$1,22 \times 10^{-4}$	10^{-4}	$3,36 \times 10^{-4}$	$2,21 \times 10^{-4}$	$3,14 \times 10^{-4}$
БилСТМ-ЛСТМ	$1,44 \times 10^{-4}$	$0,98 \times 10^{-4}$	$1,74 \times 10^{-4}$	$2,35 \times 10^{-4}$	$3,07 \times 10^{-4}$
ГРУ-ГРУ	$0,98 \times 10^{-4}$	$1,34 \times 10^{-4}$	$1,31 \times 10^{-4}$	$2,73 \times 10^{-4}$	$1,11 \times 10^{-4}$
БиГРУ-ГРУ	$1,34 \times 10^{-4}$	$1,31 \times 10^{-4}$	$1,71 \times 10^{-4}$	$2,40 \times 10^{-4}$	$4,29 \times 10^{-4}$
Трансформатор	$2,02 \times 10^{-4}$	$0,74 \times 10^{-4}$	4		$5,12 \times 10^{-4}$
МЕТО-C2C					$3,86 \times 10^{-4}$
Наш					$3,35 \times 10^{-4}$
					$3,17 \times 10^{-4}$

Таблица 3. Результаты сравнения VEPO-C2C с различными базовыми показателями по метрике оценки MAE. Здесь, 10->5 означает предсказание по 10 историческим траекториям.

Название модели	10-> 1	10->2	10->3	10->4	10->5
Кальман	$1,73 \times 10^{-4}$	$2,34 \times 10^{-4}$	$3,27 \times 10^{-4}$	$4,24 \times 10^{-4}$	$5,16 \times 10^{-4}$
ВАР	$0,87 \times 10^{-4}$	$2,12 \times 10^{-4}$	$28,6 \times 10^{-4}$	-	-
АРИМА	$2,69 \times 10^{-4}$	$3,99 \times 10^{-4}$	$5,33 \times 10^{-4}$	$6,69 \times 10^{-4}$	$1,18 \times 10^{-4}$
ЛСТМ	$0,43 \times 10^{-4}$	$0,77 \times 10^{-4}$	10^{-4}	$1,66 \times 10^{-4}$	$1,87 \times 10^{-4}$
БилСТМ	$1,50 \times 10^{-4}$	$1,52 \times 10^{-4}$	$2,35 \times 10^{-4}$	$1,01 \times 10^{-4}$	$1,42 \times 10^{-4}$
ГРУ	$0,36 \times 10^{-4}$	$0,66 \times 10^{-4}$	10^{-4}	$1,84 \times 10^{-4}$	$2,15 \times 10^{-4}$
БиГРУ	$1,53 \times 10^{-4}$	$1,65 \times 10^{-4}$	$1,34 \times 10^{-4}$	$1,72 \times 10^{-4}$	$1,56 \times 10^{-4}$
ЛСТМ-ЛСТМ	$0,70 \times 10^{-4}$	10^{-4}	$1,94 \times 10^{-4}$	$1,10 \times 10^{-4}$	$1,46 \times 10^{-4}$
БилСТМ-ЛСТМ	$0,88 \times 10^{-4}$	$0,51 \times 10^{-4}$	$1,20 \times 10^{-4}$	$1,50 \times 10^{-4}$	$1,92 \times 10^{-4}$
ГРУ-ГРУ	$0,51 \times 10^{-4}$	$0,78 \times 10^{-4}$	$1,42 \times 10^{-4}$	$1,53 \times 10^{-4}$	$1,70 \times 10^{-4}$
БиГРУ-ГРУ	$0,74 \times 10^{-4}$	$0,81 \times 10^{-4}$	$1,43 \times 10^{-4}$	$0,99 \times 10^{-4}$	$1,28 \times 10^{-4}$
Трансформатор	$1,43 \times 10^{-4}$	$1,10 \times 10^{-4}$	$0,95 \times 10^{-4}$		$1,72 \times 10^{-4}$
МЕТО-C2C	$0,53 \times 10^{-4}$	$1,46 \times 10^{-4}$			$1,94 \times 10^{-4}$
Наш		$0,74 \times 10^{-4}$			$1,60 \times 10^{-4}$

Таблица 4. Результаты сравнения VEPO-S2S с различными базовыми моделями по метрике оценки ADE. Здесь, 10->5 означает предсказание по 10 историческим траекториям.

Название модели	10-> 1	10->2	10->3	10->4	10->5
Кальман	3,42 × 10 ⁻⁴	4,62 × 10 ⁻⁴	8,22 × 10 ⁻⁴	11,52 × 10 ⁻⁴	14,29 × 10 ⁻⁴
ВАР	1,38 × 10 ⁻⁴	5,60 × 10 ⁻⁴	123,53 × 10 ⁻⁴	-	-
АРИМА	4,83 × 10 ⁻⁴	7,11 × 10 ⁻⁴	9,42 × 10 ⁻⁴	11,76 × 10 ⁻⁴	14,14 × 10 ⁻⁴
ЛСТМ	0,68 × 10 ⁻⁴	1,22 × 10 ⁻⁴	1,87 × 10 ⁻⁴	2,64 × 10 ⁻⁴	3,51 × 10 ⁻⁴
БилСТМ	2,37 × 10 ⁻⁴	2,38 × 10 ⁻⁴	2,99 × 10 ⁻⁴	3,74 × 10 ⁻⁴	4,56 × 10 ⁻⁴
ГРУ	0,59 × 10 ⁻⁴	1,05 × 10 ⁻⁴	1,62 × 10 ⁻⁴	2,27 × 10 ⁻⁴	2,99 × 10 ⁻⁴
БигРУ	2,42 × 10 ⁻⁴	2,73 × 10 ⁻⁴	4,00 × 10 ⁻⁴	4,91 × 10 ⁻⁴	5,20 × 10 ⁻⁴
LSTM-LSTM	1,11 × 10 ⁻⁴	1,59 × 10 ⁻⁴	2,13 × 10 ⁻⁴	2,73 × 10 ⁻⁴	3,38 × 10 ⁻⁴
LSTM 1,39 × 10 ⁻⁴ ГРУ-ГРУ	0,80 × 10 ⁻⁴	1,90 × 10 ⁻⁴	2,47 × 10 ⁻⁴	3,07 × 10 ⁻⁴	3,72 × 10 ⁻⁴
10-4 БигРУ-ГРУ 1,16 × 10 ⁻⁴ 1,28 × 10 ⁻⁴ 2,26 × 10 ⁻⁴ 0,83 × 10 ⁻⁴		1,23 × 10 ⁻⁴	1,74 × 10 ⁻⁴	2,31 × 10 ⁻⁴	2,93 × 10 ⁻⁴
Трансформатор		1,75 × 10 ⁻⁴	2,38 × 10 ⁻⁴	3,05 × 10 ⁻⁴	3,76 × 10 ⁻⁴
МЕТО-C2C		1,50 × 10 ⁻⁴	1,83 × 10 ⁻⁴	2,25 × 10 ⁻⁴	2,73 × 10 ⁻⁴
Наш		2,30 × 10 ⁻⁴	2,41 × 10 ⁻⁴	2,68 × 10 ⁻⁴	3,07 × 10 ⁻⁴
		1,17 × 10 ⁻⁴	1,52 × 10 ⁻⁴	2,01 × 10 ⁻⁴	2,52 × 10 ⁻⁴

5.2.2. Исследование структуры Seq2Seq VEPO-S2S

Мы провели несколько экспериментов по структуре кодера и декодера в ВЭПО-C2C для достижения оптимальных характеристик, включая ВЭПО-БигРУ-ГРУ, ВЭПО-LSTM- LSTM, ВЭПО-БилСТМ- LSTM и ВЭПО-ГРУ-ГРУ. Как показано в таблице 5, лучший результат был получен с ВЭПО-ГРУ-ГРУ. Поэтому в последующих экспериментах для дальнейших экспериментов мы использовали ВЭПО-C2C со структурой ГРУ-ГРУ.

Таблица 5. Результаты исследования различных структур Seq2Seq.

Кодировщик	названия модели	Декодер	RMSE	МАЗ	АДЕ	ФДЕ
ВЭПО-C2C	БигРУ	ГРУ	3,60 × 10 ⁻⁴	1,99 × 10 ⁻⁴	3,15 × 10 ⁻⁴	5,28 × 10 ⁻⁴
ВЭПО-C2C	ЛСТМ	LSTM	3,46 × 10 ⁻⁴	1,72 × 10 ⁻⁴	2,72 × 10 ⁻⁴	4,94 × 10 ⁻⁴
ВЭПО-C2C	БилСТМ	LSTM	4,19 × 10 ⁻⁴	2,48 × 10 ⁻⁴	3,39 × 10 ⁻⁴	5,97 × 10 ⁻⁴
ВЭПО-C2C	ГРУ	ГРУ	3,17 × 10 ⁻⁴	1,60 × 10 ⁻⁴	2,52 × 10 ⁻⁴	4,57 × 10 ⁻⁴

5.2.3. Дальнейший анализ

В отличие от оценки задач непрерывного прогнозирования траектории, мы провели оценку отдельных точек с использованием RMSE, MAE и FDE. Как видно из таблиц 6-8, ошибки прогнозирования всех моделей заметно увеличились от первой к пятой точке прогнозирования. Это объясняется значительным сокращением доступной информации для каждого прогноза при переходе от первого к последнему прогнозу. Базовый уровень РНС модели используют подход скользящего окна для прогнозирования и постепенно накапливают неточности с каждым прогнозом. И наоборот, базовые модели Seq2Seq имеют возможность для одновременного прогнозирования нескольких точек, что может уменьшить тенденцию к увеличению ошибок по сравнению с базовыми моделями RNN. Кроме того, модели временных рядов полагаются о линейных связях между несколькими временными рядами; однако в долгосрочном прогнозе задач нелинейные характеристики становятся более заметными, что приводит к быстрому увеличению неточностей. через некоторое время. Более того, наша модель почти превосходит все базовые показатели. Мы также наблюдаем аналогичные результаты между МЕТО-C2C и ВЭПО-C2C в четвертой и пятой точках. Рисунок 6 показывает, что и ВЭПО, и МЕТО являются отличными моделями для длинных последовательностей. задачи прогнозирования.

Таблица 6. Результаты количественного анализа каждой точки траектории по индексу оценки RMSE.

Название модели	Первый	Второй	Третий	Четвертый	Пятый
Кальман	$2,42 \times 10^{-4}$	$3,27 \times 10^{-4}$	$5,81 \times 10^{-4}$	$3,74 \times 10^{-4}$	$8,15 \times 10^{-4}$
ВАР	$0,98 \times 10^{-4}$	$86,61 \times 10^{-4}$		-	-
АРИМА	$3,42 \times 10^{-4}$	$6,63 \times 10^{-4}$	$9,93 \times 10^{-4}$	$13,28 \times 10^{-4}$	$16,72 \times 10^{-4}$
ЛСТМ	$0,88 \times 10^{-4}$	$2,10 \times 10^{-4}$	$3,63 \times 10^{-4}$	$5,43 \times 10^{-4}$	$7,60 \times 10^{-4}$
БилСТМ	$2,64 \times 10^{-4}$	$2,65 \times 10^{-4}$	$4,77 \times 10^{-4}$	$6,39 \times 10^{-4}$	$8,38 \times 10^{-4}$
ГРУ	$0,86 \times 10^{-4}$	$2,06 \times 10^{-4}$	$3,52 \times 10^{-4}$	$5,16 \times 10^{-4}$	$6,96 \times 10^{-4}$
БигРУ	$3,16 \times 10^{-4}$	$2,42 \times 10^{-4}$	$5,24 \times 10^{-4}$	$6,44 \times 10^{-4}$	$6,83 \times 10^{-4}$
LSTM-LSTM	$1,22 \times 10^{-4}$	$2,46 \times 10^{-4}$	$3,90 \times 10^{-4}$	$5,50 \times 10^{-4}$	$7,20 \times 10^{-4}$
BiLSTM-LSTM	$1,44 \times 10^{-4}$	$2,77 \times 10^{-4}$	$4,30 \times 10^{-4}$	$5,95 \times 10^{-4}$	$7,68 \times 10^{-4}$
ГРУ-ГРУ	$0,98 \times 10^{-4}$	$2,18 \times 10^{-4}$	$3,59 \times 10^{-4}$	$5,14 \times 10^{-4}$	$6,84 \times 10^{-4}$
10-4 БигРУ-ГРУ	$1,34 \times 10^{-4}$	$2,82 \times 10^{-4}$	$4,45 \times 10^{-4}$	$6,17 \times 10^{-4}$	$7,96 \times 10^{-4}$
10-4	$2,02 \times 10^{-4}$	$2,08 \times 10^{-4}$	$3,24 \times 10^{-4}$	$4,59 \times 10^{-4}$	$6,07 \times 10^{-4}$
Трансформатор		$2,03 \times 10^{-4}$	$2,71 \times 10^{-4}$	$3,76 \times 10^{-4}$	$5,23 \times 10^{-4}$
МЕТО-C2C		$1,44 \times 10^{-4}$	$2,47 \times 10^{-4}$	$3,76 \times 10^{-4}$	$5,22 \times 10^{-4}$
Наш					

Таблица 7. Результаты количественного анализа каждой точки траектории по индексу оценки МАЭ.

Название модели	Первый	Второй	Третий	Четвертый	Пятый
Кальман	$1,73 \times 10^{-4}$	$2,94 \times 10^{-4}$	$5,13 \times 10^{-4}$	$3,38 \times 10^{-4}$	$7,13 \times 10^{-4}$
ВАР	$0,87 \times 10^{-4}$	$81,62 \times 10^{-4}$		-	-
АРИМА	$2,69 \times 10^{-4}$	$5,26 \times 10^{-4}$	$7,99 \times 10^{-4}$	$10,77 \times 10^{-4}$	$13,62 \times 10^{-4}$
ЛСТМ	$0,43 \times 10^{-4}$	$1,11 \times 10^{-4}$	$2,01 \times 10^{-4}$	$3,11 \times 10^{-4}$	$4,40 \times 10^{-4}$
БилСТМ	$1,50 \times 10^{-4}$	$1,52 \times 10^{-4}$	$2,60 \times 10^{-4}$	$3,79 \times 10^{-4}$	$4,94 \times 10^{-4}$
ГРУ	$0,36 \times 10^{-4}$	$0,95 \times 10^{-4}$	$1,72 \times 10^{-4}$	$2,63 \times 10^{-4}$	$3,67 \times 10^{-4}$
БигРУ	$1,53 \times 10^{-4}$	$1,77 \times 10^{-4}$	$2,53 \times 10^{-4}$	$3,09 \times 10^{-4}$	$3,26 \times 10^{-4}$
LSTM-LSTM	$0,70 \times 10^{-4}$	$1,30 \times 10^{-4}$	$2,02 \times 10^{-4}$	$2,85 \times 10^{-4}$	$3,77 \times 10^{-4}$
BiLSTM-LSTM	$0,88 \times 10^{-4}$	$1,53 \times 10^{-4}$	$2,28 \times 10^{-4}$	$3,08 \times 10^{-4}$	$3,98 \times 10^{-4}$
ГРУ-ГРУ	$0,51 \times 10^{-4}$	$1,04 \times 10^{-4}$	$3,59 \times 10^{-4}$	$5,14 \times 10^{-4}$	$6,84 \times 10^{-4}$
БигРУ-ГРУ	$1,34 \times 10^{-4}$	$2,82 \times 10^{-4}$	$4,45 \times 10^{-4}$	$6,17 \times 10^{-4}$	$7,96 \times 10^{-4}$
Трансформатор	$2,02 \times 10^{-4}$	$1,09 \times 10^{-4}$	$1,58 \times 10^{-4}$	$2,20 \times 10^{-4}$	$2,93 \times 10^{-4}$
МЕТО-10-4	$0,53 \times 10^{-4}$	$2,03 \times 10^{-4}$	$2,21 \times 10^{-4}$	$2,71 \times 10^{-4}$	$2,92 \times 10^{-4}$
Наш		$0,96 \times 10^{-4}$	$1,48 \times 10^{-4}$	$2,13 \times 10^{-4}$	$2,88 \times 10^{-4}$

Таблица 8. Результаты количественного анализа каждой точки траектории по индексу оценки FDE.

Название модели	Первый	Второй	Третий	Четвертый	Пятый
Кальман	$3,42 \times 10^{-4}$	$4,62 \times 10^{-4}$	$8,22 \times 10^{-4}$	$11,52 \times 10^{-4}$	$14,29 \times 10^{-4}$
ВАР	$1,38 \times 10^{-4}$	$5,30 \times 10^{-4}$	$122,49 \times 10^{-4}$	-	-
АРИМА	$4,83 \times 10^{-4}$	$9,38 \times 10^{-4}$	$14,05 \times 10^{-4}$	$18,79 \times 10^{-4}$	$23,65 \times 10^{-4}$
ЛСТМ	$0,68 \times 10^{-4}$	$1,76 \times 10^{-4}$	$3,19 \times 10^{-4}$	$4,93 \times 10^{-4}$	$6,99 \times 10^{-4}$
БилСТМ	$2,37 \times 10^{-4}$	$2,38 \times 10^{-4}$	$4,22 \times 10^{-4}$	$6,00 \times 10^{-4}$	$7,84 \times 10^{-4}$
ГРУ	$0,59 \times 10^{-4}$	$1,48 \times 10^{-4}$	$2,75 \times 10^{-4}$	$4,20 \times 10^{-4}$	$5,86 \times 10^{-4}$
БигРУ	$2,42 \times 10^{-4}$	$2,84 \times 10^{-4}$	$4,00 \times 10^{-4}$	$4,91 \times 10^{-4}$	$5,20 \times 10^{-4}$
LSTM-LSTM	$1,11 \times 10^{-4}$	$2,06 \times 10^{-4}$	$3,21 \times 10^{-4}$	$4,52 \times 10^{-4}$	$5,98 \times 10^{-4}$
BiLSTM-LSTM	$1,39 \times 10^{-4}$	$2,41 \times 10^{-4}$	$3,61 \times 10^{-4}$	$4,89 \times 10^{-4}$	$6,32 \times 10^{-4}$
ГРУ-ГРУ	$0,80 \times 10^{-4}$	$1,66 \times 10^{-4}$	$2,76 \times 10^{-4}$	$4,02 \times 10^{-4}$	$5,42 \times 10^{-4}$
БигРУ-ГРУ	$1,16 \times 10^{-4}$	$2,23 \times 10^{-4}$	$3,65 \times 10^{-4}$	$5,06 \times 10^{-4}$	$6,60 \times 10^{-4}$
10-4 Трансформатор	$2,22 \times 10^{-4}$	$1,72 \times 10^{-4}$	$2,50 \times 10^{-4}$	$3,50 \times 10^{-4}$	$4,67 \times 10^{-4}$
0,83 $\times 10^{-4}$		$2,30 \times 10^{-4}$	$2,71 \times 10^{-4}$	$3,49 \times 10^{-4}$	$4,62 \times 10^{-4}$
МЕТО-C2C		$1,51 \times 10^{-4}$	$2,34 \times 10^{-4}$	$3,37 \times 10^{-4}$	$4,57 \times 10^{-4}$
Наш					

Предлагаемая модель VEPO-S2S состоит из многоуровневого модуля представления траектории судна (Multi-Rep) и модуля объединения и декодирования функций (FFDM). Multi-Rep специально разработан не только для интеграции информации о траектории, но и для полностью учитывать особенности судна и поведенческие предпочтения, кодируя их отчетливыми

кодировщики для обогащения представления функций. Кроме того, FFDM выбирает и объединяет вышеуказанную информацию и функции на основе текущей среды прогнозирования, что позволяет модели эффективно использовать их. Эти два преимущества делают ВЕПО-С2С точнее, чем другие базовые линии.

5.3. Исследование абляции

Исследовать функцию многоуровневых характеристик сосуда в ВЭПО-С2С и Модуль объединения и декодирования функций, мы разработали несколько экспериментов по абляции, которые представлены в следующей части:

- 1. без sa. Удалить ввод атрибутов мелкого уровня в многоуровневом сосуда.
Модуль представления траектории, включая длину, ширину, осадку и тип судна. (см. раздел 4.3.1);
- 2. без k1. Удаление предпочтений местоположения плавания в многоуровневой траектории судна
Модуль представления (см. раздел 4.3.1);
- 3. без k2. Удаление предпочтений времени рейса из многоуровневой траектории судна
Модуль представления (см. раздел 4.3.1);
- 4. без k3. Удалите настройку времени стоянки на якоре из многоуровневой траектории судна.
Модуль представления (см. раздел 4.3.1);
- 5. без p_s. Удалите компонент выбора портрета из Feature Fusion и
Модуль декодирования (см. раздел 4.3.2);
- 6. с _ж . Удалите компонент Feature Fusion из Feature Fusion и Decoding.
Модуль (см. раздел 4.3.2);
- 7. без muti_d. Удалите компонент многоголовочного декодера из Feature Fusion и
Модуль декодирования, использующий вместо этого один GRU для декодирования, который не получает информацию о траектории отдельно (см. раздел 4.3.2).

Результаты показаны в Таблице 9. Мы оценивали производительность с использованием RMSE, MAE, АДЭ и ФДЕ. Результаты показывают, что удаление компонента выбора портрета оказало наиболее существенное влияние на показатель RMSE, уменьшив его с $3,17 \times 10^{-4}$ до $4,48 \times 10^{-4}$. Это указывает на то, что компонент выбора портрета играет решающую роль в модели. Это связано с тем, что компонент выбора портрета отвечает за выбор характеристики судна, наиболее подходящие для текущих условий. Когда Компонент Portrait Selection удален, производительность модели существенно снижается. Кроме того, замечено, что удаление компонента многоголовочного декодера привело к наименьшее воздействие, с уменьшением с $3,17 \times 10^{-4}$ до $3,32 \times 10^{-4}$. Это связано с тем, что усиление декодер не влияет на общую структуру. Модель по-прежнему имеет возможность выбора и научитесь использовать соответствующие характеристики для создания точных прогнозов. Однако усиление декодера приводит к небольшому улучшению производительности модели. В соответствии с приведенным выше анализом, показатели оценки MAE, ADE и FDE показали аналогичные тенденции.

Таблица 9. Количественные результаты различных исследований абляции.

Абляция	RMSE	МАЭ	АДЕ	ФДЕ
ВЕПО-С2С	$3,17 \times 10^{-4}$	$1,60 \times 10^{-4}$	$2,52 \times 10^{-4}$	$4,57 \times 10^{-4}$
без sa	$3,53 \times 10^{-4}$	$1,88 \times 10^{-4}$	$2,96 \times 10^{-4}$	$5,27 \times 10^{-4}$
без k1	$3,50 \times 10^{-4}$	$1,82 \times 10^{-4}$	$2,88 \times 10^{-4}$	$5,07 \times 10^{-4}$
без k2	$3,50 \times 10^{-4}$	$1,88 \times 10^{-4}$	$2,96 \times 10^{-4}$	$5,19 \times 10^{-4}$
без k3	$3,55 \times 10^{-4}$	$1,95 \times 10^{-4}$	$3,07 \times 10^{-4}$	$5,38 \times 10^{-4}$
без p_s	$4,48 \times 10^{-4}$	$1,99 \times 10^{-4}$	$3,15 \times 10^{-4}$	$5,84 \times 10^{-4}$
без _fw/	$3,42 \times 10^{-4}$	$1,81 \times 10^{-4}$	$2,88 \times 10^{-4}$	$5,13 \times 10^{-4}$
о muti_d	$3,32 \times 10^{-4}$	$1,76 \times 10^{-4}$	$2,77 \times 10^{-4}$	$4,87 \times 10^{-4}$

После удаления различных нововведений производительность модели снизилась. Следовательно, модель оснащена всеми характеристиками и компонентами для достижения оптимального результата, демонстрирующие эффективность наших инновационных очков.

5.4. Качественный анализ

Для того, чтобы лучше проанализировать работу ВЭПО-С2С, мы выбрали несколько сравнительных пригодные модели для нескольких качественных анализов, как описано в этом подразделе.

5.4.1. Сравнение базовых показателей

Как показано на рисунке 12, наша модель дает точные прогнозы в обоих сценариях. по сравнению с другими базовыми показателями. Сложность прогноза увеличилась от (а) до (б). В), грузовое судно шло прямым маршрутом. Большинство моделей дали удовлетворительные прогнозы. особенно ВЕПО и МЕТО. Однако ГРУ отклонилось от истинной траектории. (б) показывает разворот контейнеровоза, где наша модель работает лучше всего. Кроме того, МЕТО-С2С модель точно предсказала первые четыре точки, но отклонилась от фактической траектории в последний пункт. Модель ГРУ-ГРУ работает лучше, чем модель ГРУ; однако это все равно изо всех сил пытается достичь удовлетворительных результатов прогнозирования. На практике неправильные прогнозы могут легко привести к несчастным случаям. Можно заметить, что результаты, предсказанные ВЭПО-С2С, были превосходит другие, что позволяет избежать проблем с безопасностью.




Рисунок 12. Прогнозы грузовых судов и контейнеровозов по различным моделям с учетом сложность прогнозов возрастает от (а) к (б). Наша модель работает лучше всего в обоих сценариях. В (а), предполагающее прямолинейное плавание грузовых судов, все модели, кроме ГРУ, достигают приличных результатов результаты прогнозирования. В (б) речь идет о повороте контейнеровоза. Кроме того, модель МЕТО-С2С также способен в некоторой степени выполнять задачи прогнозирования. Однако другие модели с трудом справляются с этой задачей. добиться удовлетворительных результатов прогнозирования.

5.4.2. Визуальный результат структуры Seq2Seq

Как видно из рисунка 13, ВЕПО-ГРУ-ГРУ более устойчив по сравнению с ВЕПО- БигРУ-ГРУ, ВЕПО- БилSTM-LSTM и ВЕПО-LSTM-LSTM. (а) изображает плавную траекторию, указывающую на нормальное плавание грузового судна. (б) показывает изогнутую траекторию, возможно, предполагая маневры уклонения нефтяного танкера. На различных типах судов и состояния движения все конструкции модели ВЭПО-С2С стабильно демонстрируют удовлетворительные результаты. производительность. Примечательно, что модель ВЭПО-С2С со структурой ГРУ-ГРУ показывает лучшие результаты. надежность.




Рисунок 13. Прогнозы траектории грузового судна и нефтяного танкера с использованием различных конструкций Модель VEPO-S2S, сложность прогнозирования постепенно увеличивается от (а) к (b). Как изображено в На графике ВЕПО-ГРУ-ГРУ достигает наилучших прогнозных показателей.

5.4.3. Качественные результаты абляции

Мы провели несколько детальных исследований, чтобы лучше проиллюстрировать изменения экспериментальных результатов до и после абляции. Семь фигур отображают результаты экспериментов по Атрибуты мелкого уровня, Предпочтение места плавания, Предпочтение времени путешествия, Предпочтение времени привязки, Компонент выбора портрета, Объединение функций Компонент и компонент многоголового декодера для буксира. Точнее, мы представить четыре траектории на каждом изображении, включая входные точки трека, метки и прогнозные результаты до и после абляции.

Для каждого рисунка очевидно, что зеленая кривая точно соответствует реальной траектории. Мы заметили, что если у судна отсутствует какой-либо из атрибутов мелкого уровня, место плавания Предпочтение, Предпочтение времени рейса или Предпочтение времени стоянки на якоре. значительные отклонения как по направлению, так и по расстоянию в прогнозируемых результатах.

На рис . 14 показаны результаты с атрибутами мелкого уровня и без них. в отсутствие атрибутов мелкого уровня, прогнозы ВЭПО-C2C отклоняются от фактической траектории в четвертой и пятой точках. Это связано с тем, что атрибуты мелкого уровня определяют инерция судна и возможности поворота. Обычно более крупные суда испытывают больше трудностей. в изменении их текущего состояния движения. Когда не хватает атрибутов мелкого уровня, модель изо всех сил пытается точно оценить эти способности судна. Поэтому в долгосрочной перспективе прогнозов, модель не может обеспечить эффективное руководство и приводит к отклонениям от прогнозов. правильная траектория на более поздних этапах.




Рисунок 14. Прогнозируемые траектории буксира, где зеленая и красная линии — прогноз. результаты с использованием VEPO-S2S с атрибутами мелкого уровня и без них соответственно. Мелкий уровень Атрибуты связаны с инерцией судна и возможностями поворота. Модель без Атрибуты мелкого уровня не могут хорошо понять эту способность, что может привести к ошибкам.

На рис . 15 показаны результаты с параметром «Предпочтение местоположения плавания» и без него. Предпочтение местоположения плавания помогает модели распознать адаптируемость судна к местности.

Суда с разной степенью адаптации к местности выбирают разные способы предотвращения столкновений. Без настройки местоположения плавания модель с трудом уловит детали маршруты, что затрудняет создание соответствующего выбора и приводит к колебаниям по прогнозируемым траекториям.




Рисунок 15. Прогнозируемые траектории буксира, где зеленые и красные линии представляют результаты прогнозирования VEPO-S2S с учетом и без учета предпочтения места плавания соответственно.

Предпочтение местоположения плавания помогает модели определить адаптируемость судна к географической среде. Если предпочтение места плавания не учитывается, модель VEPO-S2S не является правильным.

На рис. 16 показаны результаты сравнения с параметром «Время путешествия» и без него. Предпочтение времени путешествия отражает привычки экипажей и плавание судов. в разное время. Например, маневры по предотвращению столкновений различны во время периоды высокого и низкого судоходства. Без указания предпочтений времени путешествия, предсказанные результаты демонстрируют значительные колебания.




Рисунок 16. Прогнозируемые траектории буксира, где зеленая и красная линии обозначают результаты прогнозирования модели VEPO-S2S с учетом и без учета предпочтения времени рейса, соответственно. Предпочтение времени путешествия связано с привычками экипажей. Когда время путешествия Предпочтения не учитываются, модель VEPO-S2S может давать неточные прогнозы.

На рис. 17 показаны результаты с параметром времени привязки и без него. связано с привычками работы и отдыха. Траектория буксира еще больше меняется существенно, когда он находится в рабочем состоянии. Поэтому модели сложно точно определить текущее движение буксира без времени стоянки. Предпочтение, приводящее к отклонениям точек от истинной траектории.




Рисунок 17. Прогнозируемые траектории буксира, где зеленые и красные линии представляют результаты прогнозирования модели VEPO-S2S с учетом и без учета предпочтения времени стоянки, соответственно. Предпочтение времени привязки помогает модели определить привычки работы и отдыха судна. При отсутствии предпочтения времени привязки модель выдает неверные значения. оценка для каждой временной метки.

На рис . 18 показаны результаты визуального сравнения компонента «Выбор портрета» . Без компонента «Выбор портрета» результат отклоняется от реального трека. Этот потому что компонент выбора портрета может выбирать наиболее подходящие характеристики для прогноз и без него в прогноз могут быть введены нерелевантные характеристики. процесс, который приводит к значительным отклонениям в прогнозируемых результатах.




Рисунок 18. Прогнозируемые траектории буксира, где зеленая и красная линии — прогноз. результаты с использованием VEPO-S2S с компонентом выбора портрета и без него соответственно. Портрет Компонент выбора отвечает за выбор наиболее подходящих характеристик для прогнозирования. Без этого компонента модель не может выбрать подходящие характеристики для помощи в прогнозировании. что приводит к снижению устойчивости модели.

На рис . 19 показаны результаты визуального сравнения компонента Feature Fusion, который эффективно интегрирует информацию о траектории с характеристиками судна и повышает корреляция между ними. Без компонента Feature Fusion характеристики судна борьба за полное выражение, что приводит к неправильным предсказаниям.




Рисунок 19. Прогнозируемые траектории буксира, где зеленые и красные линии — прогноз.

Результаты VEPO-S2S с компонентом Feature Fusion Component и без него соответственно. Функция объединена Компонент эффективно объединяет информацию о траектории и характеристиках судна и увеличивает корреляция между обоими. Без Feature Fused Component определение характеристик судна затруднено. адекватно выражаться в модели ВЭПО-C2C, что приводит к снижению точности модели.

На рисунке 20 показаны результаты сравнения компонента многоголовочного декодера, который может регулировать уровень участия в информации о траектории и характеристиках судна. Адаптивность модели снижается при удалении компонента многоголовочного декодера. На основании этих исследований абляции модель ВЭПО-C2C демонстрирует удовлетворительную точность. и надежность.




Рисунок 20. Прогнозируемые траектории буксира, где зеленые и красные линии представляют собой результаты прогнозирования с использованием VEPO-S2S с компонентом многоголовочного декодера и без него соответственно. Компонент многоголовочного декодера регулирует использование информации о траектории и характеристики судна в процессе прогнозирования. Без него технологичность модели ВЭПО-C2C снижается. складки.

6. Выводы

Изучив соответствующую литературу, мы обнаружили, что особенности сосудов и поведенческие особенности предпочтения оказывают существенное влияние на траектории. Таким образом, данное исследование предлагает новую модель прогнозирования траектории VEPO-S2S, которая полностью учитывает информацию о траектории, особенности судна и поведенческие предпочтения. ВЭПО-C2C состоит из двух частей: Многоуровневая Модуль представления траектории судна и модуль объединения и декодирования функций. Модуль многоуровневого представления траектории судна получает информацию о траектории. (такие как долгота, широта, курс, скорость и расстояние плавания), а также многоуровневые характеристики судна, включающие атрибуты мелкого уровня (длина судна, тип, и осадка) и функции глубокого уровня (предпочтение места плавания, предпочтение времени рейса, и закрепление временных предпочтений). Они кодируются с использованием нескольких кодировщиков. Особенность Модуль слияния и декодирования направлен на выбор наиболее подходящих характеристик судна для текущую среду прогнозирования и интегрировать их с информацией о траектории перед

декодирование с помощью расширенного декодера. Результаты экспериментов показывают, что эта модель качественно превосходит другие базовые модели и демонстрирует отличную производительность на картах на основе сетки.

7. Будущие работы

В этой работе мы учли влияние особенностей и предпочтений, выходящих за рамки информации о траектории, на прогнозирование траектории. В будущем мы стремимся оптимизировать нашу модель для повышения эффективности и точности прогнозов, проверенных на более глобальных наборах навигационных данных. Кроме того, мы рассмотрим другие известные модели, такие как модель больших временных рядов. Кроме того, существуют и другие факторы, влияющие на движение судов, включая погоду, состояние моря, океанские течения и рифы. Поэтому мы стремимся включить больше влияющих факторов в процесс моделирования и провести дальнейшие исследования в более сложных сценариях.

Вклад авторов: Концептуализация, ZH; методология, ZH и XY; программное обеспечение, SL; валидация, HL и JL; формальный анализ, YZ; исследование, YZ и HL; ресурсы, HL; курирование данных, Вашингтон; письмо — подготовка первоначального черновика, XY; написание — рецензирование и редактирование, Ж; визуализация, WA и XY; надзор, С.Л. и Дж.Л. Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: Это исследование финансировалось Фондом естественных наук провинции Чжэцзян, Китай, в рамках гранта LY21E090005, а также Проектом Бюро науки и технологий Чжоушань (2021C21010).

Заявление Институционального наблюдательного совета: Неприменимо.

Заявление об информированном согласии: Не применимо.

Заявление о доступности данных: все данные, использованные в этом документе, можно загрузить с общедоступного веб-сайта: [Marinecadastre.gov/accessais](https://marinecadastre.gov/accessais). (по состоянию на 31 декабря 2021 г.).

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Сокращения

В данной рукописи использованы следующие сокращения:

АИС	Автоматическая система идентификации
Seq2Seq	Сеть «последовательность-последовательность»
ВЕПО	«последовательность» модель, ориентированная на портрет судна
Модуль многоуровневого представления траектории судна Multi-Rep	
МФДМ	модуль объединения и декодирования функций

Рекомендации

1. Ян, К.-Х.; Ву, Ч.-Х.; Шао, Ж.-К.; Ван, Ю.-К.; Се, К.-М. Интеллектуальное прогнозирование траектории судна на основе AIS с использованием bi-lstm. IEEE Access 2022, 10, 24302–24315.
2. Фоссен, С.; Фоссен, Т.И. Разработка расширенного фильтра Калмана и прогнозирование движения судов с использованием данных автоматической системы идентификации (АИС) в реальном времени. В материалах 2-й Европейской конференции по электротехнике и информатике (EECS) 2018 г., Берн, Швейцария, 20–22 декабря 2018 г.; стр. 464–470.
3. Каван, Б.; Ван, Х.; Ли, Г.; Чхантъял, К. Моделирование прогнозирования движения корабля на основе данных на основе регрессии опорных векторов. В материалах 58-го SIMS, Рейкьявик, Исландия, 25–27 сентября 2017 г.
4. Ли, Х.; Цзяо, Х.; Ян, З. Прогнозирование траектории корабля на основе машинного обучения и глубокого обучения: систематический обзор и анализ методов. англ. Прил. Артиф. Интел. 2023, 126, 107062.
5. Суо Ю.; Чен, В.; Клараунт, К.; Ян, С. Система прогнозирования траектории корабля, основанная на рекуррентной нейронной сети. Датчики 2020, 20, 5133.
6. Ван, К.; Рен, Х.; Ли, Х. Прогнозирование траектории судна на основе данных AIS и двунаправленной гру. В материалах Международной конференции 2020 года по компьютерному зрению, изображениям и глубокому обучению (CVIDL), IEEE, Наньчан, Китай, 15–17 мая 2020 г.; стр. 260–264.
7. Тан, Х.; Инь, Ю.; Шен, Х. Модель прогнозирования траектории судна на основе нейронной сети с долгосрочной кратковременной памятью. Дж. Мар, англ. Технол. 2022, 21, 136–145.

8. Парк, Дж.; Чон, Дж.; Парк, Ю. Прогноз траектории корабля на основе bi-LSTM с использованием спектрально-кластеризованных данных AIS. Дж. Мар. англ. 2021, 9, 1037.
9. Чжан С.; Ван, Л.; Чжу, М.; Чен, С.; Чжан, Х.; Цзэн, З. Двухнаправленный метод прогнозирования траектории корабля LSTM, основанный на механизме внимания. В материалах 5-й конференции IEEE по передовым информационным технологиям, электронике и автоматизации (IAEAC) 2021 г., IEEE, Чунцин, Китай, 12–14 марта 2021 г.; стр. 1987–1993 гг.
10. Бао, К.; Би, Дж.; Гао, М.; Сан, Ю.; Чжан, Х.; Чжан, В. Улучшенный прогноз траектории корабля на основе данных AIS с использованием mha-bi-gru. Дж. март. наук. англ. 2022, 10, 804.
11. Ву, Б.; Чен, П.; Чен, Л.; Моу, Дж. Прогнозирование траектории корабля: комплексный подход с использованием модели последовательностей от последовательности на основе conlstm. Дж. Мар. англ. 2023, 11, 1484.
12. Нгуен, Д.-Д.; Ван, СЛ; Али, М.И. Прогнозирование траектории судна с использованием последовательностных моделей по пространственной сетке. В материалах 12-й Международной конференции ACM по распределенным и событийным системам, Лион, Франция, 25–28 июня 2018 г.; стр. 258–261.
13. Чжан Ю.; Хан, З.; Чжоу, Х.; Ли, Б.; Чжан, Л.; Чжэнь, Э.; Ван, С.; Чжао, З.; Го, З. Meto-s2s: метод прогнозирования траектории судна на основе s2s с многосемантическим кодером и типоориентированным декодером. Океан. англ. 2023, 277, 114248.
14. Чжао Дж.; Ян, З.; Чен, Х.; Хан, Б.; Ву, С.; Ке, Р. k-gcn-lstm: Сверточная сеть на графах с k-прыжками и долговременная память для прогнозирования скорости корабля. Физ. Стат. Мех. Это приложение. 2022, 606, 128107.
15. Ван С.; Ли, Ю.; Син, Х.; Чжан, З. Прогнозирование траектории судна на основе сверточной сети пространственно-временных графов для сложные и многолюдные морские районы. Океан. англ. 2024, 298, 117232.
16. Цао, Д.; Ли, Дж.; Ма, Х.; Томизука, М. Нейронная сеть на спектрально-временном графе для прогнозирования траекторий. В материалах 2021 года Международная конференция IEEE по робототехнике и автоматизации (ICRA), Сиань, Китай, 30 мая – 5 июня 2021 г.; стр. 1839–1845.
17. Ясукава, Х.; Ёсимура, Ю. Маневренность корабля; Сейзандо: Токио, Япония, 2018 г.
18. Купер А. Почему высокотехнологичные продукты сводят нас с ума и как восстановить здравомыслие; Издательство Sams: Карнел, Индиана, США, 2004 г.
19. Лу, Дж.; Се, Л. Метод инерциальной навигации океанских транспортных средств, основанный на динамических ограничениях. Дж. Навиг. 2018, 71, 1553–1566.
20. Коул, Б.; Шамберг, Г. Фильтр Калмана без запаха для отслеживания судов на большие расстояния в геодезических координатах. Прил. Океан. Рез. 2022, 124, 103205.
21. Чжан Д.; Чу, Х.; Ву, В.; Он, З.; Ван, З.; Лю, К. Идентификация модели маневра поворота судна и экстремально краткосрочных прогнозирование траектории движения под воздействием морских течений. Океан. англ. 2023, 278, 114367.
22. Сан, К.; Тан, З.; Гао, Дж.; Чжан Г. Краткосрочное прогнозирование положения судна на основе lstm и gpr. Прил. Океан. Рез. 2022, 118, 102927.
23. Чжан Л.; Чжу, Ю.; Су, Дж.; Лу, В.; Ли, Дж.; Яо, Ю. Гибридная модель прогнозирования траектории судна на основе knn-lstm. Математика 2022, 10, 4493.
24. Гао, Д.-В.; Чжу, Ю.-С.; Чжан, Ж.-Ф.; Он, Ю.-К.; Ян, К.; Ян, Б.-Р. Новый метод tr-lstm для прогнозирования траектории корабля на основе данных АИС. Океан. англ. 2021, 228, 108956.
25. Форти, Н.; Миллефиори, LM; Браца, П.; Уиллетт, П. Прогнозирование траекторий судов на основе данных AIS с помощью последовательных рекуррентных нейронных сетей. В материалах Международной конференции IEEE по акустике, речи и обработке сигналов (ICASSP) 2020–2020 (ICASSP), виртуально, 4–9 мая 2020 г.; стр. 8936–8940.
26. Ты, Л.; Сяо, С.; Пэн, Кью; Клараунт, К.; Хан, Х.; Гуань, Э.; Чжан, Дж. St-seq2seq: seq2seq, оптимизированный по пространственно-временным функциям модель краткосрочного прогнозирования траектории судна. IEEE Access 2020, 8, 218565–218574.
27. Чен, П.; Ян, Ф.; Моу, Дж.; Чен, Л.; Ли, М. Региональное поведение судов и прогнозирование траекторий для управления морским движением: А социально-генеративно-состязательный сетевой подход. Океан. англ. 2024, 299, 117186.
28. Чжан Ю.; Хан, З.; Чжоу, Х.; Чжан, Л.; Чжэнь, Э.; Ван, С.; Чжао, З.; Го, З. Песо: Метод прогнозирования траектории судна на основе seq2seq с параллельными кодировщиками и декодером, ориентированным на судно. Прил. наук. 2023, 13, 4307.
29. Цзян, Д.; Ши, Г.; Ли, Н.; Ма, Л.; Ли, В.; Ши, Дж. Трфм-лис: Метод глубокого обучения на основе трансформатора для прогнозирования траектории судна. Дж. март. наук. англ. 2023, 11, 880.
30. Лю, RW; Лян, М.; Ни, Дж.; Юань, Ю.; Сюн, З.; Ю, Х.; Гуизани, Н. Стмгкн: Прогнозирование траектории судна с помощью мобильных периферийных вычислений с использованием пространственно-временной мультиграфовой сверточной сети. IEEE Транс. Инди. Информ. 2022, 18, 7977–7987.
31. Ли, Ю.; Ли, З.; Мэй, К.; Ван, П.; Ху, В.; Ван, З.; Се, В.; Ян, Ю.; Чен, Ю. Исследование метода прогнозирования движения многопортовых судов на основе нейронных сетей на пространственно-временных графах. Дж. Мар. англ. 2023, 11, 1379.
32. Чо, К.; Мерриенбур, Б.В.; Гульчере, К.; Богданов Д.; Бугарес, Ф.; Швенк, Х.; Бенджо, Ю. Изучение представлений фраз использование кодера-декодера gnn для статистического машинного перевода. arXiv 2014, arXiv:1406.1078.
33. Гонг, Г.; Ан, Х.; Махато, Северная Каролина; Солнце, С.; Чен, С.; Вэнь Ю. Исследование по прогнозированию краткосрочной нагрузки на основе модели seq2seq. Энергии 2019, 12, 3199.
34. Хван, С.; Чон, Г.; Чон, Дж.; Ли, Дж. Новая модель seq2seq, основанная на временных рядах, для прогнозирования температуры в процессе обжига печи. Процессы Компьютер. наук. 2019, 155, 19–26.
35. Гао, С.; Чжан, С.; Хуанг, Ю.; Хан, Дж.; Луо, Х.; Чжан, Ю.; Ван, Г. Новая архитектура seq2seq для почасового прогнозирования стока с использованием исторические данные об осадках и стоках в качестве исходных данных. Дж. Гидрол. 2022, 612, 128099.
36. Ван, Х.; Ван, С.; Чен, С.; Хуэй, Г. Прогнозирование долгосрочной динамики добычи в коллекторах плотного/сланцевого газа с помощью двухэтапной модели десяти-seq2seq, основанной на внимании: практический пример формации Дюверне. Геоэнергетические науки. англ. 2023, 223, 211495.

37. Стефенон, СФ; Семан, Ло; Акино, Л.С.; Козьло, LdS Wavelet-seq2seq-1stm с вниманием к прогнозированию временных рядов уровня плотин на гидроэлектростанциях. Энергия 2023, 274, 127350.
38. Мута, С.; Шридхар, С.; Ситхараман, Р.; Читракала, С. Прогнозирование цен на акции с использованием двунаправленной последовательности на основе LSTM для моделирования последовательностей и многозадачного обучения. В материалах 11-й ежегодной конференции IEEE по универсальным вычислениям, электронике и мобильной связи (UEMCON) 2020 г., Нью-Йорк, штат Нью-Йорк, США, 28–31 октября 2020 г.; стр. 0078–0086.
39. Он, К.; Ли, В.; Хао, З.; Лю, Г.; Хуанг, Д.; Сонг, В.; Сюй, Х.; Альхатани, Ф.; Ким, Ж.-У. Сеть tma-seq2seq для многофакторного прогнозирования температуры поверхности моря по временным рядам. Вычислитель. Матер. Продолжение. 2022, 73, 2022.
40. Цюй, К.; Чен, Х.; Лей, З.; Ли, Б.; Ду, К.; Ван, Ю. Прогнозирование амплитуды морских помех с помощью сети seq2seq с повышенным вниманием. Дистанционное Сенс. 2023, 15, 3234.
41. Асади, Н.; Ламонтань, П.; Кинг, М.; Ричард, М.; Скотт, К.А. Прогнозирование сезонного присутствия морского льда в Гудзоновом заливе с использованием обучения seq2seq. Доступно онлайн: <https://s3.us-east-1.amazonaws.com/climate-change-ai/papers/icml2021/6/paper.pdf>. (по состоянию на 1 июня 2024 г.)
42. Чжу, В.; Чжоу Р. Построение портрета сотрудника на основе глубоких нейронных сетей. В материалах 9-й Международной конференции по надежным системам и их приложениям (DSA) 2022 г., IEEE, Улумуки, Китай, 4–5 августа 2022 г.; стр. 139–142.
43. Ма, К.; Ван, З.; Ченг, П.; Лю, Х.; Ю, Х.; Чжан Х. Гибридный метод рекомендаций веб-сервисов на основе портрета пользователя. Дж. Вычислитель. 2021, 32, 197–212.
44. Чжао Дж.; Цзэн, Д.; Сяо, Ю.; Че, Л.; Ван, М. Прогноз личности пользователя на основе тематических предпочтений и анализа настроений с использованием модели LSTM. Распознавание образов. Летт. 2020, 138, 397–402.
45. Ян, С.; Чжао, Т.; Дэн, Дж. Прогнозирование занятости пользователей социальных сетей с помощью иерархических нейронных сетей, учитывающих контент. В материалах 8-й Международной конференции по большим данным и информационной аналитике (BigDIA) 2022 г., Гуйян, Китай, 24–25 августа 2022 г.; стр. 388–395.
46. Ван Н. Компьютерная интеллектуальная модель прогнозирования импульсивного вознаграждения в Интернете на основе алгоритма портрета пользователя. В материалах 4-й Международной конференции IEEE по автоматизации, электронике и электротехнике (AUTEEE) 2021 г., Шэньян, Китай, 19–21 ноября 2021 г.; стр. 545–548.
47. Мингю, З.; Сутонг, В.; Яньчжан, В.; Дуцзюань, В. Интерпретируемый метод прогнозирования академического кризиса студентов университетов предупреждение. Комплекс Интел. Сист. 2022, 8, 323–336.
48. Лю, Т.; Ма, Дж. Прогнозирование навигационного поведения корабля на основе данных АИС. IEEE Access 2022, 10, 47997–48008.
49. Сильвестр, Р. Береговая инженерия; Научное издательство Elsevier: Амстердам, Нидерланды, 1974 г.
50. Брольсма, Ю. Постоянная Международная ассоциация навигационных конгрессов. PIANC, Всемирная ассоциация инфраструктуры водного транспорта: Ассоциация в меняющемся мире, 1885–2010 гг.; ФИАНК: Брюссель, Бельгия, 2010 г. Доступно в Интернете: <https://books.google.co.jp/books?id=ZaSwYgEACAAJ>. (по состоянию на 1 июня 2024 г.).
51. Ноттебум, Т. Е. Контейнерные перевозки и порты: Обзор. Преподобный Сеть. Экон. 2004, 3, 86–106.
52. Гиллис, Д.М. Идеальное свободное распределение в динамике флота: поведенческий взгляд на движение судов в анализе рыболовства. Может. Дж. Зул. 2003, 81, 177–187.
53. Махпур, А.; Назифи, А.; Амири А.М. Разработка модели оптимизации для сокращения времени разгрузки и погрузки на причале в контейнерные порты. Иран. Дж. Наук. Технол. Пер. Гражданский. англ. 2021, 45, 2831–2840.
54. Макиннес, Л.; Хили, Дж.; Астелс, С. hdbscan: Иерархическая кластеризация на основе плотности. J. Программное обеспечение с открытым исходным кодом. 2017, 2, 205.

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и соавторам(ам), а не MDPI и/или редактору(ам). MDPI и/или редактор(ы) не несут ответственности за любой вред людям или имуществу, возникший в результате любых идей, методов, инструкций или продуктов, упомянутых в контенте.