

УДК 004.048

Поезжаева Елена Вячеславовна¹, к.т.н., профессор отделения высшего образования.

e-mail: kuzovmotors@yandex.ru

Погудин Андрей Леонидович¹, к.т.н., доцент отделения высшего образования.

e-mail: pogudin_al@mail.ru

Уфимцев Виталий Алексеевич¹, студент (специалитет)

e-mail: Cotvost@gmail.com

Вопилов Артём Вячеславович¹, студент (специалитет)

e-mail: vopilov_artem@mail.ru

¹Пермский филиал Федерального государственного бюджетного образовательного учреждения высшего образования «Волжский государственный университет водного транспорта», г. Пермь, Россия.

ОНЛАЙН ПРОГНОЗИРОВАНИЕ ТРАЕКТОРИИ ДВИЖЕНИЯ КОРАБЛЯ ПРИ ПОМОЩИ ДВУНАПРАВЛЕННОЙ РЕКУРРЕНТНОЙ НЕЙРОННОЙ СЕТИ

Аннотация. В статье рассмотрены вопросы высокоточного прогнозирования навигационного поведения судов в режиме реального времени, которое может эффективно повысить надежность решений по предотвращению столкновений и снизить риск столкновений. Прогнозирование траектории с помощью модели BI-LSTM-RNN может обеспечить безопасность навигации и помочь в планировании траектории и мониторинге рисков.

Ключевые слова: прогнозирование, навигация, рекуррентные нейронные сети, траектория, мониторинг рисков.

Введение. Чтобы судно избежало столкновения, оно должно прогнозировать поведение других судов, чтобы оценить риск столкновения. Высокоточное прогнозирование навигационного поведения судов в режиме реального времени может эффективно повысить надежность решений по предотвращению столкновений и снизить риск столкновений. Алгоритмы прогнозирования поведения при навигации можно разделить на две категории: офлайн и онлайн прогнозирование. Многочисленные автономные алгоритмы прогнозирования используются в области оценки траектории и восстановления данных. В автономном прогнозировании данные о траектории вводятся в фиксированную формулу или обученную модель. Эти алгоритмы недостаточно гибки для адаптации к реальным прогнозным данным; им также не хватает своевременности и высокой эффективности.

Предыдущие алгоритмы онлайн-прогнозирования не могли изучить или сохранить опыт предыдущих исправлений данных. Примеры исследований онлайн-прогнозирования включают модель прогнозирования траектории корабля, основанную на регрессии гауссовского процесса, предложенную Мао Эт Аль. [1], в которой 24-минутная траектория корабля была смоделирована и предсказана путем экстраполяции существующих данных корабля

Рекуррентные нейронные сети (RNN) могут достигать высокой точности для задач машинного обучения с данными атрибутов временных рядов. В RNN обратная связь обеспечивается от выходной переменной к входной [2,3]. Переменная обратной связи

содержит сеть задержки времени. Однако обучение RNN является сложным, и сходимость не может быть гарантирована.

1. Модель обучения поведению при навигации. RNN используют направленные циклы для решения проблем в контексте входных узлов. RNN преодолевают связь между традиционным слоем структуры нейронной сети и скрытым слоем. Переход между каждым узлом слоя больше не является входом скрытого слоя. RNN — это модель последовательностей [2,3,3,4], которая может надлежащим образом обрабатывать данные последовательности любой длины. При обработке данных АИС текущее состояние связано только с предыдущими состояниями судна. Базовая структура сети RNN изображена на рисунке 1.




Рисунок 1 - Базовая структура сети RNN

На рисунке, t представляет время, x — входные данные, O — выходные данные, S — состояние сети, W — вес обновления, V — коэффициенты между ячейками и выход, а U — коэффициент между входом и ячейкой. Идея структуры RNN состоит в том, чтобы в полной мере использовать информацию из предыдущей последовательности, что характерно для традиционных нейронных сетей. Предполагается, что все входы или выходы независимы друг от друга. Однако многие задачи обработки естественного языка оцениваются по контексту. Следовательно, это предположение имеет свои ограничения. RNN напрямую транслируется в циркулирующую нейронную сеть или RNN, потому что разные входные данные проходят через одну и ту же нейронную сеть, а разница скрыта предыдущим состоянием скрытого слоя. Как показано на рисунке 1, развернутая RNN находится слева, а сетевая структура расширенной RNN — справа.

RNN содержит входные единицы, помеченные $\{x_0, x_1, \dots, x_t, x_{t+1}\}$, выходные единицы, помеченные $\{y_0, y_1, \dots, y_t, y_{t+1}\}$, и скрытые единицы, помеченные $\{s_0, s_1, \dots, s_t, s_{t+1}\}$. Скрытые узлы выполняют наиболее важную работу⁴ [5]. Происходит односторонний поток информации от входа к скрытым единицам к единицам вывода (рис. 2). В некоторых случаях RNN нарушает односторонний характер второго потока, и загрузочная информация возвращается скрытому устройству из выходного устройства. Этот процесс называется обратной проекцией, и входные данные скрытого слоя включают состояние предыдущего скрытого слоя. Узлы слоя могут быть подключены к следующему слою или другим узлам.




Рисунок 2 - Схема соединения ячеек

2. Принцип работы модуля LSTM. Модуль LSTM — это специальный модуль RNN, который может решить проблему долгосрочной зависимости. В блоке LSTM состояние клетки контролирует отбрасывание и добавление информации через ворота для достижения функций забывания и запоминания [6–7]. LSTM выполняет выборочные операции с полученными знаниями, используя три структуры ворот: ввод, вывод и пропуск. Структура LSTM (рис. 3) позволяет автоматически обновлять весовые коэффициенты в режиме реального времени, чтобы предотвратить исчезновение и расширение градиента.

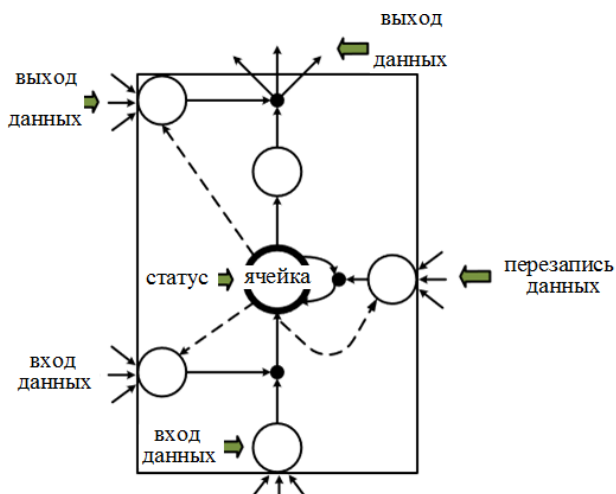


Рисунок 3 - Схема структуры клеточной единицы с долговременной и кратковременной памятью (LSTM)

3. Модель прогнозирования навигационного поведения судна. Для проверки достоверности модели были выбраны данные АИС о траекториях 11 032 судов из порта Тяньцзинь за 2015 год. Данные включали 36 807 928 координатных точек, занимающих 8,58 ГБ. Данные АИС с января по октябрь включали 29 277 849 точек и составляли обучающую группу. Данные АИС за Ноябрь-декабрь включал 7 530 103 точки и формировал группу проверки. Блок-схема полной модели прогнозирования показана на рисунке 4.

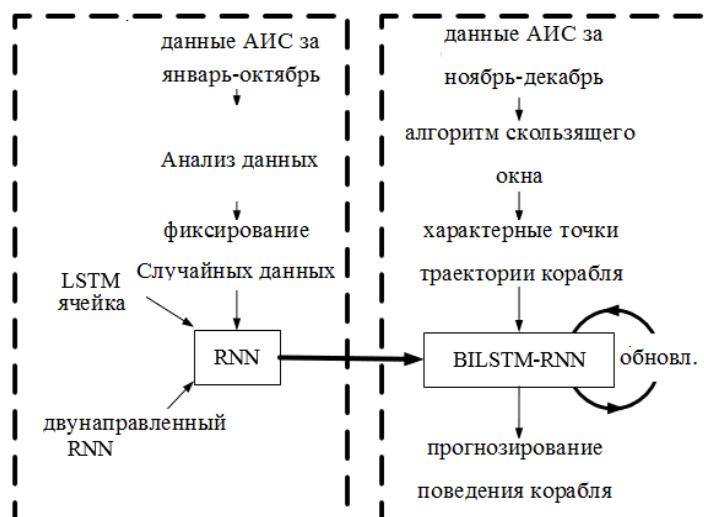


Рисунок 4 - Блок-схема модели прогнозирования навигации с использованием BI-LSTM-RNN

4. Анализ параметров для корабля, встречающего другой корабль. Корабль должен предсказать поведение приближающегося корабля и принять эффективную стратегию предотвращения столкновения. В BI-LSTM-RNN в качестве входных значений

берутся текущие и исторические данные о судне АИС, а будущее положение судна принимается в качестве выходного значения сети; затем выходные данные можно сравнить с фактическими данными о местоположении корабля. Данные АИС являются многомерными и многопараметрическими для характеристики поведения корабля; например, данные включают в себя направление, положение и скорость судна, изменяющиеся с течением времени. В тестовых данных АИС каждое судно было разделено в соответствии с его идентификатором морской подвижной службы (MMSI). Корабли были отсортированы по временным меткам, согласно данным АИС за июнь (рис. 5).




Рисунок 5 – Трафик судов, использующих АИС для района порта Тяньцзинь

Алгоритм сети удаляет данные с низкими значениями траектории и сохраняет данные с экстремальными значениями траектории. Эта операция обеспечивает сжатие и должна быть сохранена. Данные с высокими значениями траектории называются характерными точками траектории корабля и ключевыми характерными точками. В характерных точках исходная траектория сильна в данных траектории корабля АИС. При потере такой точки возможность восстановления исходной траектории значительно снижается. Точки, которые не являются ключевыми характерными точками, могут быть упрощены для достижения эффекта сжатия. Исключение некоторых трековых данных неизбежно вызывает искажение; порог определяется между коэффициентами сжатия и искажения.

Традиционные алгоритмы прогнозирования обладают ограниченной универсальностью, основаны на фиксированной математической модели и не подходят для запоминания тренировочных данных корабля заранее. Обычные алгоритмы не могут быть адаптивно изменены, а точное предсказание и оценка целевого объекта невозможны, поэтому универсальность слаба. BI-LSTM-RNN можно применять для повышения универсальности путем сохранения навигационных привычек судов, включенных в большие данные АИС, и использования операции «забыть» в отдельных случаях данных об одном корабле. Объект прогнозируется в режиме онлайн, и характеристики текущего корабля могут быть запомнены на короткий период времени. Таким образом, можно точно предсказать навигационное поведение корабля.

5. Применение BI-LSTM-RNN в реальных условиях. На рисунке 6 видно, что хотя каждое преобразование новых данных о судне изображение вызовет явление отскока, оно может быстро сойтись и стабилизироваться за короткое время. Примерно после 15 серий обучения прогностическая эффективность BI-LSTM-RNN оказалась стабильной. Надежность прогноза навигационного поведения составляла 10 м и менее в пределах точности GPS-позиционирования. Затем в качестве модуля прогнозирования применялся BI-LSTM-RNN.



Рисунок 6 - Схема прогнозирования поведения корабля

Экспериментальные результаты показывают, что BI-LSTM-RNN обучена прогнозировать положение одного корабля за короткое время, как показано на рисунках 15 и 16. Из рисунка 16 видно, что хотя каждое преобразование новых данных о судне изображением вызовет явление отскока, оно может быстро сойтись и стабилизироваться за короткое время. Примерно после 15 серий обучения прогностическая эффективность BI-LSTM-RNN оказалась стабильной. Надежность прогноза навигационного поведения составляла 10 м и менее в пределах точности GPS-позиционирования. Затем в качестве модуля прогнозирования применялся BI-LSTM-RNN.

6. Ожидаемые результаты. Результаты эксперимента в порте Китая подтвердили надежность модели. Прогнозирование траектории с помощью BI-LSTM-RNN может обеспечить безопасность навигации и помочь в планировании траектории и мониторинге рисков. Это исследование обеспечивает теоретическую основу для разработки инновационных интеллектуальных систем предотвращения столкновений для беспилотных судов, прогнозирования навигационного поведения других судов и снижения рисков управления службой движения судов (СДС). Это исследование также обеспечивает теоретическую основу для последующих исследований. BI-LSTM-RNN подходит для отслеживания отправок, классификации и идентификации судов. Кроме того, определенное состояние судна можно использовать для оценки будущей навигационной траектории, что в конечном счете помогает прогнозировать будущее поведение судна и маневрировать, а также вырабатывать точную стратегию предотвращения столкновения.

Заключение. Выбор RNN для характеристик временных рядов данных АИС больших данных позволяет проводить обучение общим правилам маневрирования судов и характеристик движения. Добавление модуля LSTM улучшает потерю градиента, вызванную данными бесконечной последовательности при обучении цикла. RNN может запомнить общие черты больших данных AIS и забыть о личностных различиях. Таким образом, у RNN есть автономный выбор: запомнить или забыть. Включая двустороннюю структуру RNN, сеть может изучать информацию, предоставленную историческими данными, и оптимизировать сеть, используя будущие данные. Текущий прогноз может установить сильную корреляцию, связанную с контекстом. Обученный BI-LSTM-RNN может точно прогнозировать будущее поведение судов при навигации и корректировать параметры в режиме реального времени, используя существующие данные в качестве входных данных.

Список литературы:

1. Мао, Ч.Х.; Пан, К.; Инь, Б.; Лу, Ю. Н.; Сюй, Х.О. Прогнозирование навигационной траектории корабля на основе регрессии гауссовского процесса. Технол. иннов. заявл. 2017, 4, 28–29.
2. Уильямс Р.Дж.; Зипсер, Д.А. Алгоритм обучения для непрерывной работы полностью рекуррентных нейронных сетей. Нейронные вычисления. 2014, 1, 270–280.
3. Хан, М.; Си, Дж.; Сюй, С.; Инь, Ф.Л. Прогнозирование хаотических временных рядов на основе нейронной сети рекуррентных предикторов. IEEE транс. Сигнальный процесс. 2004, 52, 3409–3416.
4. Бланко, А.; Дельгадо, М.; Пегалахар, М.К. Реально закодированный генетический алгоритм для обучения рекуррентных нейронных сетей. Нейронная сеть. 2001, 14, 93–105.
5. Перлматтер, Б.А. Изучение траекторий пространства состояний в рекуррентных нейронных сетях. NeuralComput. 1988, 1, 263–269.
6. Кумар, Дж.; Гумер, Р.; Сингх, А. К. Модель прогнозирования рабочей нагрузки на основе LongShortTermMemoryRecurrentNeuralNetwork (LSTM-RNN) для облачных центров обработки данных. Процедура Компьютер. науч. 2018, 125, 676–682.
7. Хохрайтер, С.; Шмидхубер, Дж. Долговременная и кратковременная память. Нейронные вычисления. 1997, 9, 1735–1780.

ONLINE PREDICTION OF SHIP TRAJECTORY USING A BIDIRECTIONAL RECURRENT NEURAL NETWORK

Vitaly A. Ufimtsev, Artyom V. Vopilov, Elena V. Pozhelyaeva, Andrey L. Pogudin

Abstract. The paper considers high-precision real-time prediction of navigational behavior of ships, which can effectively improve the reliability of collision avoidance solutions and reduce the risk of collisions. Trajectory prediction using BI-LSTM-RNN model can ensure safe navigation and help in trajectory planning and risk monitoring.

Keywords: prediction, navigation, recurrent neural networks, trajectory, risk monitoring.