



Статья

Прогнозирование характеристик высокоскоростных последовательных каналов связи на основе глубокой нейронной сети (DNN) — преобразователь Каскадная модель

Лиинь Ву ¹, Цзиньян Чжоу ¹, Хайнин Цзян ¹, Си Ян ¹, Юнжун Чжан ² и Иньан Чжан ^{1*}

¹ Школа связи и электронной инженерии, Университет Цзишюу, Цзишюу 416000, Китай; 2022700814@stu.jsu.edu.cn (LW); 2022700812@stu.jsu.edu.cn (JZ); 2023700812@stu.jsu.edu.cn (HJ); ynkj@163.com (XY)

² Шаньдунская компания Yunhai Guochuang в области инноваций в области облачных вычислительного оборудования, Ltd., Цзинань 250101, Китай; sdzyz1989@163.com * Переписка: zyh149032@jsu.edu.cn

Аннотация: Уровень проектирования физических характеристик канала оказывает решающее влияние на качество передачи высокоскоростных последовательных каналов связи. Однако проектирование канала требует сложного процесса моделирования и проверки. В этой статье предлагается модель каскадной нейронной сети, состоящая из глубокой нейронной сети (DNN) и преобразователя. Эта модель принимает физические характеристики в качестве входных данных и импортирует однобитовый отклик (SBR) в качестве соединения, которое улучшается за счет прогнозирования частотных характеристик и параметров эквивалентера. В то же время анализ целостности сигнала (SI) и оптимизация канала достигаются за счет прогнозирования глазковых диаграмм рабочих запасов канала (COM). Кроме того, для оптимизации гиперпараметров (HPO) используется байесовская оптимизация, основанная на гауссовском процессе (GP). Результаты показывают, что каскадная модель DNN-Transformer обеспечивает высокоточные прогнозы нескольких показателей при прогнозировании и оптимизации производительности, а максимальная относительная ошибка результатов тестового набора составляет менее 2% при архитектуре эквивалентера 3-отводной передачи. FFE, RX CTLE с двойным усилением постоянного тока и 12-отводный RX DFE, который более мощный, чем другие модели глубокого обучения, с точки зрения способности прогнозирования.

Ключевые слова: высокоскоростная связь; целостность сигнала; глазковая диаграмма; операционная маржа канала; каскадная модель



Цитирование: Ву, Л.; Чжоу, Дж.; Цзян Н.Х.; Ян Х.; Жан Ю. Чжан Ю

Прогнозирование характеристик высокоскоростных последовательных каналов связи на основе глубокой нейронной сети (DNN) — Каскадная модель трансформатора.

Электроника 2024, 13, 3064. <https://doi.org/10.3390/electronics13153064>.

Академический редактор: Шин-Хонг Лю

Поступила: 1 июля 2024 г.

Пересмотрено: 24 июля 2024 г.

Принято: 31 июля 2024 г.

Опубликовано: 2 августа 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

Поскольку полоса пропускания технологий проводной последовательной связи достигает уровня ГГц, обеспечить эффективную передачу сигнала путем простой оптимизации диэлектрика и структуры компоненты уже невозможно. В высокоскоростных системах последовательной связи страдают от серьезных проблем с целостностью сигнала (SI) из-за скин-эффекта, диэлектрических потерь, перекрестных помех, отражений и джиттера; поэтому анализ SI становится все более строгим на этапе проектирования высокоскоростных последовательных каналов связи. Имитационный анализ SI обычно состоит из двух этапов: решателей электромагнитного поля (EMFS) и моделирования схемной системы [1]. В первую очередь, EMFS используется для получения S-параметров, характеризующих частотную характеристику схемы. Затем эти S-параметры импортируются в систему схемной модели для моделирования во временной области, чтобы получить основные показатели SI, включая глазковую диаграмму, импульсную характеристику и формы переключений.

Хотя традиционный анализ SI, основанный на физических моделях высокоскоростных каналов связи, может обеспечить высокую точность, он требует много времени и компьютерных ресурсов. Интерфейс алгоритмической модели спецификации информации входного/выходного буфера (IBIS-AMI) – это поведенческая модель, которая моделирует поведение ввода/вывода и алгоритм связи высокоскоростных последовательных каналов, упрощая внутренние физические детали [2]. По сравнению с физическими моделями он имеет преимущества в скорости, простоте и низком потреблении ресурсов, но имеет низкую точность и недостаточную гибкость. Сравнение стандартных шаблонов соответствия является еще одним широко используемым методом [3]. Это позволяет быстро и интуитивно оценить производительность

отбрасывает запасы канала из-за необходимости строго удовлетворять дискретным метрикам [4]. Напротив, метод рабочего запаса канала (COM) может эффективно преодолеть этот недостаток путем поиска оптимального проектного пространства в всего канала в форме отношения сигнал/шум (SNR). По сравнению с традиционными метриками SI, такими как глазковые диаграммы коэффициент битовых ошибок (BER), подход COM демонстрирует такие преимущества, как более простое управление, более высокая скорость и более эффективное тестирование. Очевидно, что по сравнению с оценкой канала Приложение 69B для Ethernet 10 Гбит/с (10 GbE), использование COM является более точным [5]. Хотя подход COM может обеспечить эффективный способ оценки и оптимизации высокоскоростных каналов, он требует многочисленных итераций для пространственного поиска и недостаточного для анализа каналов с высокой пропускной способностью.

Машинное обучение (МО) в последние годы широко используется при моделировании и проектировании высокоскоростных каналов связи и демонстрирует возможность повышения эффективности анализа SI. Авторы [4,6–10] искали особенности в данных моделирования и обучали модели искусственной нейронной сети (ANN), глубокой нейронной сети (DNN) и машины опорных векторов наименьших квадратов (LS-SVM) для замены моделирования схемных систем для точного прогнозирования показателей во временной (TD) и частотной области, таких как высота глаза (EH)/ширина глаза (EW) и обратные потери (RL)/вносимые потери (IL); однако получение данных моделирования требует многовычислительных ресурсов и времени. Нейронные сети с прямой связью (FNN), случайная лесная регрессия (RFR) и машины опорных векторов (SVM) используются для достижения простых прогнозов данных моделирования [11–13], например, для прогнозирования S-параметров и импульсных характеристик. При работе с более сложными данными моделирования традиционные методы машинного обучения могут потерять многие функции. Рекуррентная нейронная сеть (RNN) — это модель машинного обучения, которая может эффективно фиксировать особенности сложных данных, особенно для данных последовательностей, таких как S-параметры и импульсные характеристики. Авторы [14–20] используют архитектуру RNN и Long Short-Term Memory (LSTM) для создания суррогатных моделей для прогнозирования формпереходных характеристик сложных высокоскоростных каналов связи. Эти независимые суррогатные модели могут выполнять анализ SI на основе данных моделирования, но не могут учитывать физические параметры каналов. Анализ SI на основе физических параметров требует более сложных методов машинного обучения, и авторы [21–24] достигли эффективных прогнозов физических параметров, используемых для оценки производительности высокоскоростного соединения, путем объединения нескольких алгоритмов глубокого обучения. Более того, на основе машинного обучения может быть достигнута оптимизация сбалансированной архитектуры для высокоскоростных последовательных каналов [4,25–27]. В заключение, прогнозирование производительности и оптимизация архитектуры [28] являются двумя важными частями приложений машинного обучения для высокоскоростных каналов.

В этой статье предлагается каскадная модель DNN-Transformer для анализа SI и оптимизации высокоскоростных последовательных каналов. В этой модели можно использовать EMFS и моделирование схемных систем, а напрямую прогнозировать метрики SI, включая значения EH/EW, IL/RL, импульсную характеристику и значения COM, в соответствии с физическими параметрами. Между тем, оптимизация каналов может быть достигнута с помощью этой модели для прогнозирования соответствующих значений COM и параметров эвалайзера для каналов с различными конфигурациями эвалайзера. Кроме того, байесовская оптимизация, основанная на гауссовском процессе (ГП), используется для оптимизации гиперпараметров при одних и тех же условиях для разных комбинаций моделей. По сравнению с прогнозированием производительности высокоскоростного канала с использованием традиционного машинного обучения [6–10], DNN-Transformer может напрямую использовать физические параметры канала для анализа, и точность его прогнозирования значительно выше. Для прогнозирования данных моделирования, таких как импульсные характеристики, DNN-Transformer может захватывать больше функций, и его способность прогнозирования более точна, чем та, которая достигается при использовании только модели RNN [14] или LSTM [20] для создания суррогатной модели. Результаты показывают, что модель DNN-Transformer может обеспечить более эффективное прогнозирование. Производительность и осуществимость предлагаемого метода иллюстрируются данными прогнозирования и графическими результатами, приведенными в

Основные положения этой статьи можно резюмировать следующим образом: (1) На

основе ключевых физических параметров каналов модели нейронных сетей используются для непосредственного анализа производительности канала, и это позволяет избежать трудоемких процессов решения ЭДС и моделирования схемных систем.

Стальная часть этого документа организована следующим образом. В разделе 2 обсуждаются основные принципы построения моделей, в разделе 3 описывается процесс построения моделей. В разделе 4 описываются принципы методов SI и SOM, в разделе 5 описывается, как был создан набор данных моделирования. В разделе 4 была создана идея дизайна дин-трансформатор и набор данных моделирования. В разделе 4 рассмотрена конструктивная идея дин-трансформатор, представлены модель и тестовые метрики. В разделе 5 приведены численные результаты демонстрирующие модель и представленность тестовых метрики. В разделе 5 приведены численные результаты демонстрирующие прогнозирующая эффе-ктивности нашей модели. Наконец, раздел 6 завершает статью, прогнозирующая эффе-ктивности нашей модели. Наконец, раздел 6 завершает статью.

2.1. Целостности сигнала и 4-параметры 2.1.

Помимо увеличения скорости передачи информации неэффективные методы передачи сигналов становятся очевидными. Последовательная цифровая передача данных и высокоскоростные методы передачи сигналов становятся очевидными. Последовательная цифровая передача данных и высокоскоростные методы передачи сигналов становятся очевидными. Последовательная цифровая передача данных и высокоскоростные методы передачи сигналов становятся очевидными.




Рисунок 1. Общая структура схемы SerDes.

Основная цель анализа SI — выявить и уменьшить факторы, вызывающие убытки, такие как основная цель анализа SI — обнаружить и уменьшить факторы, вызывающие потери, такие как сглаживание, отражение и перекрестные помехи. С одной стороны SI можно анализировать с точки зрения как сглаживания, отражения и перекрестных помех. С другой стороны SI можно анализировать в частотной области, как показано на рисунке 2а. В основном это касается в себя IL, RL, вносимые потери. Частотная область как показано на рисунке 2а. В основном это касается в себя IL, RL, отклонение вносимых потерь (ILD) и отношение вносимых потерь к перекрестным помехам (ICR), которые в последствии изменение (ILD) и соотношение вносимых потерь к перекрестным помехам (ICR), которые в последствии являются основой для оценки. С другой стороны SI можно оценить в временной области, например, с помощью диаграмм моделирования, переходных процессов, кривых ванных битовых диаграмм, коэф. эффективности, как показано на рисунке 2б.

Критический метод традиционного анализа SI предполагает получение S-параметров.

Эти параметры содержат полные характеристики частотной области (FD) канала передачи и предоставляют большой объем информации по таким аспектам, как отражение, перекрестные помехи и потери. Более того, S-параметры можно использовать при моделировании во временной области для получения таких данных, как глазковые диаграммы и кривые ваны.




Рис. 2. (а) ФД, (б) ТД. Иллюстрация двух различных методов моделирования обнаружения SI.

2.2. Операционная маржа канала традиционного анализа SI включает сбор S-параметров.

Эти параметры содержат полные характеристики частотной области (FD) канала передачи и предоставляют большой объем информации по таким аспектам, как отражение, перекрестные помехи и потери. Более того, S-параметры можно использовать при моделировании во временной области для получения таких данных, как глазковые диаграммы и кривые ваны. Этот подход обеспечивает относительно точную и справедливую среду для физического проектирования каналов с учетом различных факторов, таких как потери, отражение, межсимвольная интерференция (ISI), дисперсия ISI. Метод COM — это метод определения характеристик высокоскоростного последовательного канала, рекомендованный рабочей группой IEEE 802.3 по тестированию каналов на соответствие. Официальное определение перекрестных помех и ISI, которое используется для тестирования, соответствует требованиям канала. Официальное определение гласит: «COM — это показатель качества (QOM) для каналов, определяемый минимумом для генерации такой архитектуры и S-параметры канала» [29]. Этот подход обеспечивает относительно точную и справедливую среду для физического проектирования каналов с учетом различных факторов, таких как потери, отражение, межсимвольные помехи (ISI), дисперсия ISI, перекрестные помехи и требования SI транзистора [30]. Как показано в уравнении (1), COM может быть спецификацией устройства, что позволяет относительно точно оценить производительность канала и нажимается отношением доступной амплитуды сигнала A_s к амплитуде статистического шума A_n . Влияние каналов агрессора на каналы жертвы. Влияние э квалайзеров было

учитывается в последующих версиях метода COM, а значение метода, основанного на COM, на COM можно улучшить, выбрав настройки параметров э квалайзера. Следовательно, (1)

вычисление COM также может определить, соответствует ли качество канала требованиям транзистора.

Требования SI [30]. Ком показано в уравнении (1) COM можно выразить в отношении амплитуды сигнала и статистического шума. Как показано в уравнении (1), COM можно выразить в отношении амплитуды сигнала и статистического шума. Как показано в уравнении (1), COM можно выразить в отношении амплитуды сигнала и статистического шума.

характеристику, применение алгоритмов э квалайзера передатчика и приемника и выполнение статистических расчетов шума. На рисунке 2 представлена блок-схема построения модели COM (1) для каналов жертвы и агрессора. Кроме того, модель также учитывает помехи и корпуса передатчика и

приемника S_{tr}/r_p , окончательное сопротивление R_d , э квалайзеры. Процесс получения COM включает в себя несколько шагов, включая определение и фильтры. Чтобы лучше моделировать реальные каналы, модель COM включает гауссов белый шум и джиттер на стороне приемника. На рисунке 4 показан подробный процесс применения COM алгоритмов расчета стоимости.

расчеты. На рисунке 3 представлена блок-схема построения модели COM и изображены два пути для каналов жертвы и агрессора. Кроме того, модель также учитывает помехи и корпуса передатчика и приемника S_{tr}/r_p , окончательное сопротивление R_d , э квалайзеры и фильтры. Чтобы лучше моделировать реальные каналы, модель COM включает гауссов белый шум и джиттер на стороне приемника. На рис. 4 показан подробный процесс COM.

расчет стоимости. На рисунке 3 представлена блок-схема построения модели COM и изображены два пути для каналов жертвы и агрессора. Кроме того, модель также учитывает помехи и корпуса передатчика и приемника S_{tr}/r_p , окончательное сопротивление R_d , э квалайзеры и фильтры. Чтобы лучше моделировать реальные каналы, модель COM включает гауссов белый шум и джиттер на стороне приемника. На рис. 4 показан подробный процесс COM.

расчет стоимости. На рисунке 3 представлена блок-схема построения модели COM и изображены два пути для каналов жертвы и агрессора. Кроме того, модель также учитывает помехи и корпуса передатчика и приемника S_{tr}/r_p , окончательное сопротивление R_d , э квалайзеры и фильтры. Чтобы лучше моделировать реальные каналы, модель COM включает гауссов белый шум и джиттер на стороне приемника. На рис. 4 показан подробный процесс COM.

дисперсию шума в передатчике, дисперсию остаточной амплитуды ISI, дисперсию амплитуды джиттера. В COM анализе амплитуда джиттера $\sigma_{\text{джиттер}}$ преобразовывается в вертикальный шум в момент выборки t_s . Кроме того, $\sigma_{\text{ХТК}}$ представляет собой общую дисперсию перекрестных помех от всех путей помех, $\sigma_{\text{н}}$ обозначает гауссовский белый шум в точке выборки приемника.




Рисунок 3: Типичная модель COM.




Рисунок 4: Процесс расчета COM.

Подход COM предполагает изучение всех возможных комбинаций параметров TX. Подход COM является заделкой и квалайзеров в пределах установленного диапазона, чтобы найти конфигурацию, которая максимизирует FOM. Этот процесс определяет значения A_s и A_n , которые приводят к оптимальному FOM. Факторы влияния на A_s и A_n включают: джиттер, перекрестные помехи и шум. COM учитывает несколько традиционных методов оценки качества канала, таких как дрожание, высота глаз и ширина, но COM служит комплексным показателем для оценки последовательного канала. Он может иметь ширину, но COM служит

$$FOM = 10 \times \log_{10} \frac{A_s^2}{\sigma_{\text{Техас}}^2 + \sigma_{\text{ИСИ}}^2 + \sigma_{\text{джиттер}}^2 + \sigma_{\text{ХТК}}^2 + \sigma_{\text{н}}^2} \quad (2)$$

Числитель A_s получается из амплитуды импульсного отклика в момент t_s , который соответствует основному курсору импульсной характеристики $h(t)$. Знаменатель включает в себя сумму дисперсий всех компонентов шума, джиттера и помех. $\sigma_{\text{Техас}}^2$ представляет собой дисперсию шума в передатчике, $\sigma_{\text{ИСИ}}^2$ обозначает дисперсию остаточной амплитуды ISI, и $\sigma_{\text{джиттер}}^2$ указывает на изменение амплитуды джиттера. В анализе COM учитывается джиттер путем преобразования горизонтального джиттера в вертикальный шум в момент выборки t_s . Кроме того, $\sigma_{\text{ХТК}}^2$ представляет собой общую дисперсию перекрестных помех от всех путей помех, а $\sigma_{\text{н}}^2$ обозначает Гауссовский белый шум в точке выборки приемника. Подход COM предполагает изучение всех возможных комбинаций параметров TX. и квалайзеров в пределах установленного диапазона, чтобы найти конфигурацию, которая максимизирует FOM. Этот процесс определяет значения A_s и A_n , которые приводят к оптимальному FOM. Традиционные методы основаны на различных показателях, таких как дрожание, высота глаз и ширина, но COM служит комплексным показателем для оценки последовательного канала. Это позволяет существенно сократить время вычислений и количество итераций, а также обеспечивает точную оценку производительности канала как до, так и после выравнивания.

3.2. Конфигурация COM и настройка э квалайзера

В э той работе используется программа версии COM 4.0, предоставленная IEEE 802.3. Конфигурация ссылается на расширенную настройку моделирования COM (eCOM) с USB4 Gen4. стандарта и включает в себя э лементы стандарта 50 GBASE-KR. Настройки конфигурации PAM4, как показано в Таблице 2, используют комбинацию передатчика FFE и CTLE и DFE на стороне приемника. Эта конфигурация включает в себя коэ ффициенты отводов TX FFE. и RX DFE, адаптив ный диапазон усиления постоя нного тока и положения нулевого полю са RX CTLE. Дополнительные параметры включают количество уровней сигнала, обозначаемое L. Для сигналов PAM4: L установ лено на 4. Согласно рекомендуемой настройке PAM4 на основ е USB4, символ скорость установлена на 20 ГБд, а вых одное дифференциальное пиковое напря жение передатчика установлено на 0,4 В, обозначается как Av. Стандарт USB4 Gen4 предполагает, что PAM3 следует использовать в качестве метода модуля ции. Настройки COM для PAM3 примерно такие же, как и для PAM4. за исклю чением того, что скорость передачи символов установлена на 25,6 ГБд, а L — на 3.

Таблица 2. Настройка параметров COM.

Параметр	Симв ол	Параметр	Единица
Скорость передачи символов	Ф Б	20	ГБд
Количество уровней сигнала	л	4	
Объем памяти интерфейса	М	32	
Коэ ффициент ошибки детектора цели	DER0	10 8	
Вых одное напря жение передатчика, жертва	Средней	0,4	В
CTLE усиление постоя нного тока	gDC	[12:1:0]	дБ
CTLE усиление постоя нного тока2	gDC_HP	[6:1:0]	дБ
CTLE HP полю с	fHP_PZ	0,25	ГГц
CTLE ноль	fZ	ф 6/2,5	ГГц
CTLE полю с1	fP1	ф 6/2,5	ГГц
CTLE полю с2	ф П2	ф 6	
Глав ный курсор FFE	с (0)	0,62	
предшественник FFE	с (1)	[-0,18:0,02:0]	
Пост курсор FFE	в (1)	[0,38:0,02:0]	
Длина ДФ Э	Нб	12	—
Предел величины DFE	bmax(1)	0,75	
	bmax(2) Nb)	0,2	
порог прох ода COM	й	3	дБ

На основ е приня той конфигурации TX FFE + RX CTLE + RX DFE прогноз параметры включают коэ ффициенты отводов FFE, коэ ффициент усиления по постоя нному току CTLE и коэ ффициенты отводов. из ДФ Э. Данные TX FFE и RX CTLE получают ся путем поиска значений FOM. в о всем расч етном пространстве, а коэ ффициенты DFE определя ются по импульсная х арактеристика h(t), соответствующая оптимальному Ф ОМ На SI существенно влия ет пост курсоры ближе к основному курсору, тогда как более удаленные пост курсоры оказывают минимальное воздействие. влия ние, поэ тому прогнозируются только первые четыре пост курсора DFE.

3.3. Разделение набора данньк

Всего для данной работы было собрано 325 каналов. В э том наборе данньк было 280 каналов. использовался для создания набора данньк глазковой диаграммы называемого набором данньк А, и было использовано 215 каналов. создать набор данньк для COM и указать параметры э квалайзеров, упомя нутые как набор данньк В. Из-за влия ния FOM подх од COM использует другой э квалайзер метод оптимизации параметров полосковых и микрополосковых систем, что приводит к

Обучающий набор	184	140
Набор проверки	40	40
Тестовый набор	56	40 (5 из проверочного набора) 325
Общий		8 из 20

4. Построение каскадной модели и обучение
ослабленной способности модели ML. Следовательно, мы стандартизировали набор данных В.

использованием полосковых каналов. Среди 215 каналов в наборе данных В являются полосковыми. Математически эквивалентно набору данных, в котором для каждого из 215 каналов подается две каналы. Согласно Вматематическому описанию, результат анализа и синтеза базовой сетевой сетевой стандартной части набора [33]. Эта модель имеет решающее значение для реализации нейронных сетей и их свойств. Составляет основную единицу DNN. Структура этой модели подробно изображена в Таблице 3.

Рисунок 6. = (, представляет п вх однь признаков нейрона, а

Таблица 3. Настройки разделения набора данных .
=(,) и (,) . Веса обозначает весовой вектор, отвечающий за линейно-взвешенную связь.

вектор оптимизируется в нейронных сетях для повышения точности прогнозов. Линейно-взвешенный вектор одной		Количество каналов
результат Z можно выразить следующим образом: Наборы данных А: 320		Б: 215 (170 от А)
Обучающий набор	184	140
Набор проверки	40	40

На рис. 6 изображена структура модели МП-нейрона. Разница между Z и смещением θ используется в качестве входных данных для функции $f(\cdot)$. Функция $f(\cdot)$

называется функцией активации и используется для получения выходного сигнала нейрона. θ можно считать фиксированным значением, а также является целью оптимизации 4.1. DNN нейронная сеть. В этой статье функция ReLU принята в качестве функции активации, поскольку она может более эффективно работать с данными. Модель МП, разработанная посредством анализа и синтеза основных свойств нейронов [31]. Эта модель имеет решающее значение для реализации нейронных сетей и ReLU (4) составляет основную единицу DNN. Структура этой модели изображена на

Рисунок 6. $x = (x_1, x_2, \dots, x_n)^T$ представляет п вх однь признаков нейрона, а $w = (w_1, w_2, \dots, w_n)^T$ обозначает весовой вектор, отвечающий за линейно-взвешенную связь. В DNN вектор w оптимизируется для задач регрессии, классификации и распознавания. DNN — это широко используется для задач регрессии в производстве и оценке производительности [4,6–9,32]. Прогнозы. Линейно-взвешенный вектор Z можно выразить следующим образом. DNN, используемая в этой статье, как показано на рисунке 7, принимает стандартную структуру с несколькими скрытыми слоями, а также в одном слое и в одном слое линейной регрессии [33], использует полностью связанную сетевую архитектуру между своими нейронами. и (3)




Рисунок 6. Структура модели МП-нейрона.

На рис. 6 изображена структура модели МП-нейрона. Разница между Z и смещением θ используется в качестве входных данных для функции $f(\cdot)$. Функция $f(\cdot)$ называется функцией активации и используется для получения выходного сигнала нейрона. θ можно рассматривать как вес входного x_0 с фиксированным значением 1, а также является целью оптимизации нейронной сети. В этой статье функция ReLU принята в качестве функции активации, поскольку она может более эффективно считывать возникновение переобучения. Формула для этого показана на Уравнение (4).

$f_{ReLU}(x) = \max(0, x)$ (4)

Входные данные функции активации обычно используются в качестве входных данных для соседних слоев. DNN могут выполнять такие задачи, как регрессия, классификация и распознавание. DNN — это широко используется для задач регрессии в производстве и оценке производительности [4,6–9,32].

DNN, используемая в этой статье, как показано на рисунке 7, имеет стандартную структуру с несколькими скрытыми слоями, а также входным слоем и выходным слоем линейной регрессии [33] и

Рисунок 7. Структура модели DNN, используемая архитектуру между своими нейронами.




Рисунок 7. Структура модели DNN, используемая архитектуру между своими нейронами.

Чтобы модель лучше сходилась, модель обучения обычно требует затрат, разрыва между предсказанными моделью значениями и фактическими значениями. В этой функции стоимости для оценки разрыва между значениями, предсказанными моделью, и фактическими значениями. В статье в качестве функции стоимости принята Smooth L1 [34]:

гладкий
$$L_1(y, \hat{y}) = \begin{cases} 0.5(y - \hat{y})^2 & \text{если } |y - \hat{y}| \leq 1 \\ |y - \hat{y}| & \text{иначе} \end{cases} \quad (5)$$

Где y и $\hat{y}$ — это значения, полученные из модели и фактические значения соответственно. Поскольку функция потерь используется для оценки качества модели, то оптимизатор для обратного распространения ошибки и непрерывной минимизации функции стоимости. Модель параметров веса модели постоянно обновляется, пока не будет достигнута оптимальная производительность. После сравнения нескольких различных оптимизаторов для бинарного выбора был выбран оптимизатор Адама [35].


4.2. Трансформатор для регрессии

Точность параметров эвкализера и значений COM, прогнозируемых напрямую каналом. Точность параметров эвкализера и значений COM, непосредственно прогнозируемых параметрами функций канала, относительно низкая. В этой работе однобитовый ответ (SBR) для параметров функций относительно низкий. В этой работе однобитовый отклик (SBR) до и после выравнивания сначала прогнозируется на основе функциональных параметров канала, и после того, как корректировка сначала прогнозируется на основе параметров функций канала, затем параметры эвкализера и значения COM определяются в соответствии с преимпульсным затем параметрами эвкализера и значения COM определяются в соответствии с преимпульсным откликом. Импульсный отклик необходимо использовать как временной ряд для прогнозирования. Прогнозирование импульсной реакции. Импульсный отклик необходимо использовать как временной ряд для прогнозирования. Традиционно для прогнозирования временных рядов используются модели RNN или LSTM, но они имеют определенные ограничения. Модель Transformer может эффективно улучшить градиент. Произведения имеют определенные ограничения. Модель Transformer может эффективно улучшить градиент. Проблема взрыва, которая возникает в LSTM, за счет использования механизмов внимания, тем самым улучшая точность прогнозирования [36].

Формула механизма внимания показана в уравнении (6). В основном он состоит из К (ключ) и V (значение), а также модуля softmax. Когда Q и V извлекаются из K и V, то K и V идентичны, то называется механизмом самовнимания.

Внимание
$$\text{Внимание}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (6)$$

Полная архитектура Transformer в первую очередь включает в себя уровень внедрения, уровень позиционного кодирования, уровень кодера, уровень декодера и выходной уровень. В этой работе, поскольку наша задача — это задача прогнозирования временных рядов, а не задача NLP, позиционный кодировщик был удален. Существует прогноз временных рядов, который рассматривается как уровень кодирования, который имеет прогнозируемые значения в виде вектора, соответствующего задаче задачи регрессии; модели необходимо генерировать только одно выходное значение, соответствующее каждому моменту времени, и ей не требуется декодер для генерации выходных последовательностей. Использование только

$$\frac{f(x) - f(x_0)}{f(x_0)} = f(x) \times \frac{1}{f(x_0)} \times \frac{1}{x - x_0} \times (x - x_0) \times \left[1 + \frac{1}{2} \left(\frac{f'(x_0)}{f(x_0)} \right) (x - x_0) + \frac{1}{6} \left(\frac{f''(x_0)}{f(x_0)} \right) (x - x_0)^2 + \dots \right] \quad (7)$$


где N_C представляет количество каналов в наборе данных, N_P — общее количество функций канала, а X — матрица $N_C \times N_P$. Элемент x_{ij} обозначает количественное значение конкретного физического признака канала: например, x_{11} соответствует значению признака длины первого канала.

DNN, используемая в каскадной модели, может быть представлена уравнением (9):

$$Y = \text{FDNN}(Z, \theta) \\ = W(l) \cdot \text{ReLU}(\dots \cdot (W(2) \cdot \text{ReLU}(W(1)X + \theta(1)) + \theta(2)) \dots) + \theta(l) \quad (9)$$

где Z представляет собой линейно взвешенный выход одной матрицы X и весов модели W , как описано в уравнении (3), а θ представляет собой смещение. Индекс l обозначает слой модели DNN, который включает входной слой, скрытые слои и выходной слой. Наша сеть использует в общей сложности четыре различных модели DNN с различными гиперпараметрами: Y_f для прогнозирования спектральных характеристик, Y_e для прогнозирования параметров эвалайзера, Y_{COM} для прогнозирования глазковой диаграммы и Y_{COM} для прогнозирования COM.

Расширенная матрица X_f получается путем горизонтального объединения входной матрицы X первой модели DNN с выходом Y_f :

$$X_f = [X \ Y_f] \\ = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1N_P} & y_{1I} & y_{1R} & \dots & y_{2I} & y_{2R} \\ x_{21} & x_{22} & & & & & & & \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & & \vdots & \vdots \\ x_{N_C1} & x_{N_C2} & \dots & x_{N_CN_P} & y_{N_C I} & y_{N_C R} \end{bmatrix} \quad (10)$$

где вектор-столбец $y_I = (y_{1I}, y_{2I}, \dots, y_{N_C I})^T$ представляет прогнозируемый канал IL и $y_R = (y_{1R}, y_{2R}, \dots, y_{N_C R})^T$ представляет предсказанный канал RL.

Чтобы повысить точность прогнозируемого значения COM, импульсный отклик извлекается из SBR до и после выравнивания в инструменте COM. В качестве основного курсора принимается момент времени, соответствующий пику, а в качестве требуемого SBR выбираются амплитуды четырех предкурсоров и восьми посткурсоров, определяемые интервалом выборки COM. Затем импульс каждого канала выравнивается и вставляются соответствующие временные метки, образуя последовательный вектор признаков. Уравнение (11) представляет собой последовательность значений амплитуд. После этой обработки модель Трансформатора можно использовать для точного прогнозирования SBR.

$$SBR_1(t) = \text{FTrans}[x_{11}(t), x_{12}(t), \dots, x_{1N_P}(t), y_{1I}(t), y_{1R}(t)] \\ SBR_1 = [SBR_1(t_0), \dots, SBR_1(t_1)] \quad (11)$$

где FTrans обозначает используемую модель преобразователя, $SBR_1(t)$ представляет SBR, соответствующий входному вектору признаков канала в определенный момент времени, а SBR_1 представляет последовательность SBR канала. t_0 и t_1 — левая и правая границы временного диапазона соответственно.

Подавая SBR в последующую модель DNN с различными параметрами, можно получить прогноз параметров эвалайзера с помощью уравнения (12):

$$A^{\text{P}} = \text{FDNN}(SBR_1, SBR_2, \dots, \text{СБР НЦ}) \quad (12)$$

Пути интегрирования параметров эвалайзера с входными данными, имеющими спектральные характеристики, расширенная матрица SBR_{Req} характеристик, строится (t) для прогнозирования пост-выравнивания.

СБР. Эта матрица с помощью уравнения (13) затем преобразуется в зависящую от времени последовательность в соответствии с методологией, представленной в уравнении (11).

$$\begin{aligned} \text{СБРек}_{\text{н}}(t) &= \text{FTrans}[x_{\text{NC1}}(t), \dots, x_{\text{NCNP}}(t), \\ &\quad y_{\text{NCI}}(t), y_{\text{NCR}}(t), Y_{\text{е}}^{\text{е}}(t)] \\ \text{СБРек}_{\text{н}} &= [\text{SBR}_{\text{е}}(t_0), \dots, \\ &\quad \text{СБРек}_{\text{н}}(t), \dots, (t, \text{SBR}_{\text{е}})] \\ \text{Да}_{\text{е}}^{\text{е}} \text{ От в оды} &= \text{Краны} \text{FFE-NC} \text{у}, \text{у} \text{DCgain} \text{FFE-NC} \text{DFE-NC} \end{aligned} \quad (13)$$

Наконец, полученный SBR после выравнивания объединяется с Xf для формирования окончательного результата. вх одные функции для прогнозирования значения COM.

Перед формальным обучением каскадной модели мы стандартизировали вх одные данные, а freq применила стратегию предварительного обучения. Первоначально модели DNN F DNN(X) и F DNN(X), предназначенные для прогнозирования спектральных характеристик и параметров э квалайзера соответственно, обучались независимо, и соответствующие им параметры собирались. Эти предварительно обученные модели DNN затем были интегрированы с одной моделью Transformer для построения полной каскадной модели для прогнозирования параметров э квалайзера и COM, как показано на рисунке 9. Для обучения каскадной модели в качестве функции стоимости использовалась Smooth L1, и алгоритм Адама был применен для обновления параметров модели. С помощью набора инструментов optuna структурирование модели и оптимизация гиперпараметров (HPO) были выполнены посредством байесовской оптимизации с использованием GP [37,38]. В качестве функции сбора данных была выбрана функция ожидаемого улучшения (EI) с начальным набором из 10 точек наблюдения, позволяющая получить э ффективный HPO в пределах вычислительно возможного объема.

Посравнению с поиском глобальной сетке, поиском случайной сетке и методами поиска пополам байесовская оптимизация более э ффективна для HPO и требует меньше времени на оптимизацию. Кроме того, в э той статье используется метод перекрестной проверки K-Fold для повышения надежности оценки модели.

После завершения обучения модели ее прогнозные возможности можно оценить с помощью нескольких различных показателей. Одной из э тих метрик, показанной в уравнении (14), я вля ется RMSE. Операция возведения в квадрат в RMSE повышает чувствительность к ошибкам, что делает ее особенно чувствительной к выбросам. Эта повышенная чувствительность также может сделать его чрезмерно чувствительным к выбросам, но операция извлечения квадратного корня не может интуитивно отразить фактическую величину ошибки.

$$\text{CKO} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_n - \hat{y}_n)^2} \quad (14)$$

MAE рассчитывается по среднему значению абсолютных разностей прогнозируемого и фактического значений. Посравнению с RMSE, MAE менее чувствителен к выбросам и обеспечивает более интуитивное отражение фактической величины ошибок. Однако э то может привести к недооценке влияния ошибок.

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_n - \hat{y}_n| \quad (15)$$

MAPE — э тосреднее значение абсолютных процентных различий между прогнозируемыми и фактическими значениями. Посравнению с RMSE и MAE, MAPE легче понять и позволяет сравнивать результаты прогнозирования в разных масштабах. Он больше подходит для ситуаций с значительными изменениями фактических значений. Однако, когда фактические значения близки к нулю, ошибка может стать большой, поэтому MAPE не подходит для наборов данных, содержащих нулевые или близкие к нулю значения.

$$\text{MAPE} = \frac{1}{n} \sum_{j=1}^n \frac{|y_n - \hat{y}_n|}{y_n} \quad (16)$$

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{|y_n - \hat{y}_n|}{y_n} \quad (16)$$

5. Численные результаты

В данной работе модель нейронной сети была построена с использованием библиотеки Python 5. Численные результаты на основе Пайторча 2.0.1. Компьютер, используемый для расчета модели, включал в себя GeForce. В этой работе RTX 4070 и Intel Core i5-12600 KF 3,7 ГГц, на основе библиотеки Python.

Пайторча 2.0.1. Компьютер, используемый для расчета модели, включал видеокарту GeForce. RTX 4070 и Intel Core i5-12600 KF 3,7 ГГц.

5,1. И как показано на рисунке 10, IL и RL представляют собой потери на частоте Найквиста, а модель предсказания IL более точна, чем предсказания RL. Это связано с тем, что IL является первичным. Как показано на рисунке 10, IL и RL представляют собой потери на частоте Найквиста, а модель на него влияет. Из диэлектрических потерь и вх одные характеристики, в том числе прогнозы IL, связанные с диэлектрическими потерями, более точны, чем прогнозы RL. Это связано с тем, что IL в первую очередь параметров И наоборот, на RL влияют дополнительные факторы, такие как импеданс, на который влияет из диэлектрических потерь и вх одные характеристики, включая соответствие параметров, связанных с диэлектрическими потерями, и, сложные формы трасс, что усложняет его прогнозирование. Поэ тому точность з теров. И наоборот, на RL влияют дополнительные факторы, такие как несоответствие импедансов и прогнозирования IL лучше, чем прогнозирования RL. Оносительная ошибка прогнозирования RL представляет собой сложную форму трассы, усложняющую его прогнозирование. Следовательно, точность прогнозирования IL 17,4%, ноэ то годостаточно для точного предсказания глазковых диаграмм, а COM лучше, чем предсказание RL. Оносительная ошибка прогноза RL составила 17,4%, ноэ то достаточно для обеспечения точного прогнозирования глазковых диаграмм значений COM.





Рис. 10. Сравнение прогнозируемых и фактических значений IL (а) и RL (б):


5.2. ENU/EW глазковой диаграмм

[illegible]

Электроника 2024, 13, 3064	Глаз	Модуля ция	RMSE	MAЭ	МАПЭ	МРЭ (%)
	ЭН(МВ)	ПАМВ	$4,8 \times 10^{-1}$	$3,3 \times 10^{-1}$	$5,7 \times 10^{-3}$	2,5
		ПАМ4	$4,0 \times 10^{-1}$	$2,9 \times 10^{-1}$	$8,1 \times 10^{-3}$	2,8
	Р ЭБ (UI)	ПАМВ	$4,4 \times 10^{-3}$	$3,4 \times 10^{-3}$	$9,3 \times 10^{-3}$	2,7
		ПАМ4	$4,4 \times 10^{-3}$	$3,6 \times 10^{-3}$	$1,2 \times 10^{-2}$	3,5
	14 из 20					



(a) PAM3



(b) PAM4

Рисунок 11. Относительные ошибки глазковых диаграмм для каналов тестового набора в двух форматах модуля ции. Рисунок 11. Относительные погрешности глазковых диаграмм для каналов тестового набора в двух форматах модуля ции.

5.3. COM

Таблица 4. Прогнозирование глазковых диаграмм с помощью модели DNN.

Поскольку многие значения SBR до и после курсора близки или равны нулю, глаз модуля ции MAPE и MRE не подходят для оценки точности прогнозов SBR, и только RMSE и MAE используются для оценки точности прогнозирования для SBR.						
Для SBR $5,7 \times 10^{-3}$ до выравнивания 40 тестовых каналов RMSE составил $7,3 \times 10^{-4}$, а MAE составил $6,3 \times 10^{-4}$. Для SBR после выравнивания RMSE составил $1,1 \times 10^{-3}$, а MAE составил $1,6 \times 10^{-4}$. Ниже мы используем случайно выбранный канал тестового набора, чтобы проиллюстрировать производительность прогнозирования SBR. Как показано на рисунке 12, так и после выравнивания можно с высокой точностью предсказать с помощью модели Трансформатора.	ПАМВ	RMSE	MAЭ	МАПЭ	МРЭ (%)	
	ПАМВ	$4,8 \times 10^{-1}$	$3,3 \times 10^{-1}$	$5,7 \times 10^{-3}$	2,5	
	ПАМ4	$4,0 \times 10^{-1}$	$2,9 \times 10^{-1}$	$8,1 \times 10^{-3}$	2,8	
	ПАМВ	$4,4 \times 10^{-3}$	$3,4 \times 10^{-3}$	$9,3 \times 10^{-3}$	2,7	
	ПАМ4	$4,4 \times 10^{-3}$	$3,6 \times 10^{-3}$	$1,2 \times 10^{-2}$	3,5	

5.3. КОМ

Поскольку многие значения SBR до и после курсора близки или равны нулю, MAPE и MRE не подходят для оценки точности прогнозов SBR, а только RMSE. и MAE используются для оценки точности прогнозирования SBR. Для СБР ранее выравнивание 40 тестовых каналов, RMSE составил $7,3 \times 10^{-4}$, а MAE составил $6,3 \times 10^{-4}$. Для SBR после выравнивания, RMSE составил $1,1 \times 10^{-3}$, а MAE составил $1,6 \times 10^{-4}$. Ниже мы используем случайно выбранный канал (ID: 3) из тестового набора, чтобы проиллюстрировать прогноз SBR производительность. Как показано на рисунке 12, как предварительная, так и поствыравнивающая SBR можно с высокой точностью предсказать с помощью модели Трансформатора.

Для формата сигнала PAM4 на рисунке 13 представлена краткая демонстрация. Мы выбрали конфигурация э квалайзера, включающая 3-от-одный TX FFE, RX CTLE с двойным усилением постоянного тока, и 12-от-одный RX DFE (далее именуемый стандартной конфигурацией э квалайзера). Как показано на рисунке 13, каналы №7 и №30 имеют большие относительные погрешности из-за их сложные формы. Некоторые каналы с высоким RL, например каналы №7–№9, также э кспонат значительная относительная ошибка. Относительная ошибка прогнозируемых значений COM для каждого теста каналов одится в пределах 2%, демонстрируя способность модели DNN-Transformer достигать требуемая точность прогноза.

Здесь показаны влияние различных комбинаций э квалайзеров на точность прогнозирования. значений COM подвергаются глубокому анализу. Как показано в таблице 5, мы настроили пять разных комбинаций э квалайзера. Результаты показывают, что предложенная нами каскадная модель достигает ожидаемая э ффективность прогнозирования для различных комбинаций э квалайзеров. Однако э очевидно, что сокращение разнообразия э квалайзеров ослабляет обобщение модели. возможности и снижает точность прогнозирования. Когда был включен только DFE, RMSE увеличилось до $1,6 \times 10^{-1}$, а MRE достиг 17,5%. Мы свзяваем э то с оптимизацией метод э того э квалайзера в рамках COM и тот факт, что каскадная модель также учитывает прогнозы как для CTLE, так и для FFE. По э тому мы скорректировали структуру сети путем удаления неиспользуемых э квалайзеров в каскадной модели для разных

комбинации э квалайзера. Данная модификация привела к улучшению х арактеристик модели. точ ность прогно зирования знач ений COM, при э том MRE снизилась с 17,5% до 11,5%.






Рисунок 13. Относительная ошибка и значения COM для кодирования PAM4 (ID: 1–40) в стандартной конфигурации э квалайзера.

Таблица 5. Прогнозируемые значения ошибок COM для каскадной модели.	
Ценности COM глубоко анализируются. Как показано в Таблице 5, мы настроили пять различных комбинаций э квалайзера. Результаты показывают, что предложенная нами каскадная модель достигает 4,5 × э фfectiveness FFE + CTLE + 12 отводов DFE различных комбинаций э квалайзеров. Однако очевидно, что сокращение разнообразия э квалайзеров ослабляет модель.	2,0%
CTLE + 4-отводный DFE Рисунок 13. DFE 4,2 × 10-2 3,2 × 10-2 4,1 × 10-3 3-отводный FFE +	1,7%
Относительная ошибка и значения COM для кодирования PAM4 (ID: 1–40) в стандартном э квалайзере CTLE + 12 отводов DFE.	5,7%
12-отводный DFE	17,5%

Здесь глубоко анализируется влияние различных комбинаций э квалайзеров на точность прогно зирования знач ений COM. Как показано в Таблице 5, мы настроили пять различных комбинаций э квалайзера. Результаты показывают, что предложенная нами каскадная модель обеспечивает ожидаемую э фfectiveness прогно зирования для различных комбинаций э квалайзеров. Однако очевидно, что сокращение разнообразия э квалайзеров ослабляет э фfectiveness модели.

Ниже тестовый канал (D0-3) используется для иллюстрации прогнозирующих возможностей модели. Ниже приведены результаты работы модели DFETR для тестовых данных FFE. Как показано на рисунке 14а, результаты модели в целом удовлетворительны, по результатам прогнозирования модель результатов прогнозирования для основного усилителя по постоянному току FFE для 40 тестовых каналов, как показано на рисунке 14б, также указывают на высокий уровень точности:



(б) Усиление постоянного тока CTLE

[illegible]

Таблица 6. Прогнозируемые значения ошибок различных моделей.

Модель	RMSE	МАЭ	МАПЭ	МРЭ (%)
ДНН	$6,9 \times 10^{-2}$	$4,3 \times 10^{-2}$	$7,8 \times 10^{-3}$	6,5
ЛСТМ	$5,3 \times 10^{-2}$	$4,4 \times 10^{-2}$	$6,4 \times 10^{-3}$	2,0
ДНН+ЛСТМ	$5,0 \times 10^{-2}$	$4,1 \times 10^{-2}$	$6,0 \times 10^{-3}$	1,8
Трансформатор	$4,7 \times 10^{-2}$	$3,7 \times 10^{-2}$	$5,5 \times 10^{-3}$	1,7
ДНН+Трансформатор	$4,6 \times 10^{-2}$	$3,5 \times 10^{-2}$	$5,1 \times 10^{-3}$	1,6

Как показано в таблице 7, мы сравнили модель DNN-Transformer с моделями, представленными в разделе «Введение» с точки зрения функциональности. Традиционный LSTM [20]

структура не могла обеспечить прогнозирование при переменных физических параметрах. Традиционный модели машинного обучения, такие как модели SVM [13], RFR [12] и DNN [9], имеют ограниченные возможности. возможности обработки последовательностей и, следовательно, не могут предсказать переходные формы сигналов. Модель GNN-RNN [21] упрощает взаимосвязанные компоненты схемы, то есть что некоторые реальные параметры теряются и производительность снижается. Вышеуказанные модели не могли обеспечить оптимизацию каналов, а RFR [12] мог только завершить FD прогноз. Напротив, предлагаемый DNN-Transformer более практичен. Эта модель может эффективно решать вышеуказанные поведенческие задачи и работает лучше, чем другие модели в RMSE и MAE для прогнозирования значения COM. В связи с возросшей сложностью этой модели время вывода увеличивается, но она по-прежнему имеет значительное преимущество по времени по сравнению с традиционным ЭМ-моделированием, время принятия единственного решения которого составляет несколько часов.

Таблица 7. Функциональное сравнение различных моделей для высокоскоростных каналов связи.

Модель	Физический Параметры Переменная	Переходный процесс Формы волны Прогноз	ФД Прогноз	Связь Оптимизация	Графический процессор/процессор Время (мс)	RMSE	MAE
СВМ [13]	Да	Нет	Нет	Нет	<5 *	$3,8 \times 10^{-1}$	$3,1 \times 10^{-1}$
РФР [12]	Да	Нет	Да	Нет	<5 *	$4,8 \times 10^{-1}$	$3,8 \times 10^{-1}$
ДНН [9]	Да	Нет	Нет	Нет	<5	$6,9 \times 10^{-2}$	$4,3 \times 10^{-2}$
ЛСТМ [20]	Нет	Да	Нет	Нет	<5	$5,3 \times 10^{-2}$	$4,4 \times 10^{-2}$
ГНН-РНН [21]	Да	Да	Нет	Нет	567,1	\	\
ДНН-Трансформатор	Да	Да	Да	Да	792,8 *	$4,6 \times 10^{-2}$	$3,5 \times 10^{-2}$

* Время вывода графического процессора.

6. Выводы

В данной статье предлагается каскадная нейронная сеть DNN-Transformer для эффективного анализа SI в высокоскоростных последовательных каналах связи. В процессе создания набора данных мы использовали стандарты USB4 Gen4 и 50GBASE-KR для проектирования печатных плат и электромагнитной совместимости. моделирования и использовал физические параметры конструкции каждого канала в качестве входных данных для модели. Эта модель DNN-Transformer используется в этой статье для извлечения признаков из параметры физического проектирования каналов и успешно прогнозировать данные глазковой диаграммы и значения COM тестовых каналов. Кроме того, эта модель глубокого обучения может успешно спрогнозировать SBR до и после выравнивания, а также основные параметры квалайзера для различных комбинации также точно предсказываются. Для обучения модели мы использовали Метод байесовской оптимизации на основе ГП для НПО. Наконец, в этой статье сравниваются DNN-Transformer с различными другими моделями, такими как модели DNN, LSTM, Transformer и DNN-LSTM. Результаты показывают, что наша каскадная модель DNN-Transformer точно обеспечивает прогнозирование производительности и оптимизацию архитектуры выравнивания для высокоскоростных последовательных каналов MRE в результатах прогнозирования COM для тестового набора с квалайзером конфигурация, включающая 3-отводный TX FFE, RX CTLE с двойным усилением постоянного тока и 12-отводный RX DFE, составляет 1,6%.

Вклад автора: концептуализация, LW, JZ и YZ (Иньан Чжан); методология, JZ и HJ; программное обеспечение, LB; проверка, LW, JZ и YZ (Иньан Чжан); формальный анализ, LW, HJ и YZ (Иньан Чжан); исследование, LW; ресурсы, LW, YZ (Иньан Чжан) и YZ (Юнжэ Чжан); курирование данных, LW и YZ (Иньан Чжан); письмо — первоначальный черновик подготовка, LW; написание — просмотр и редактирование, XY, YZ (Иньан Чжан) и YZ (Юнжэ Чжан); визуализация, LB; надзор, XY, YZ (Иньан Чжан) и YZ (Юнжэ Чжан); администрация проекта, LW; приобретение финансирования, LW, YZ (Иньан Чжан) и XY. Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: Работа выполнена при поддержке Национального фонда естественных наук Китая (грант No. 61861019, 62161012), Департамент образования провинции Хунань (грант № 22B0525, 21A0335),

Китайский фонд постдокторской науки (грант № 2024M751268) и аспирантура
Программа Университета Цзицзун (грант № Jdy23035).

Заявление о доступности данных: данные, используемые для подтверждения результатов исследования, доступны в течение статьи.

Конфликт интересов: автор Юнжэнь Чжан работал в компании Shandong Yunhai.
Guochuang Cloud Computing Equipment Industry Innovation Company Limited. Остальные
авторы заявляют, что исследование проводилось при отсутствии какой-либо коммерческой или финансовой
отношения, которые могут быть истолкованы как потенциальный конфликт интересов.

Сокращения

В данной рукописи использованы следующие сокращения:

Глубокая нейронная сеть	DNN;
ЛСТМ	Нейронная сеть с долговременной краткосрочной памятью;
СБР	Однобитовый ответ;
Целостность сигнала	SI
Операционная рентабельность	COM-канала;
расширенная операционная рентабельность	канала eCOM;
-----	Гауссов процесс;
оптимизация гиперпараметров	HPO;
ЭМ	электромагнитный;
ЭМС	решатель электромагнитного поля;
IBIS-AMI	Спецификация информации о буфере ввода/вывода Интерфейс алгоритмической модели;
ЕН	высота глаз;
РЭБ	ширина глаз;
РЛ	обратные потери;
-----	вносимые потери;
ТД	область времени;
ФД	частотная область;
МП	машинное обучение;
Машина опорных векторов	SVM;
LS-SVM	Машина опорных векторов наименьших квадратов;
FNN	Нейронная сеть прямого распространения;
РФР	случайная лесная регрессия;
РНН	Рекуррентная нейронная сеть;
ФФЭ	э-квалайзер прямой связи;
ДФЭ	э-квалайзер с обратной связью по решению;
КТЛЭ	линейный э-квалайзер непрерывного времени;
-----	отклонение вносимых потерь;
МЦР	отношение вносимых потерь к перекрестным помехам;
ИСИ	межмольная интерференция;
ФОМ	показатель заслуг.

Рекомендации

1.

Холл, Ш. Чертовозымы, НЛ Улучшенная целостность сигнала для высокоскоростных цифровых проектов; John Wiley & Sons: Хобокен, Нью-Джерси, США, 2009 г.; стр. 201–206.

2.

Яң Дж; Заргаранйезд, А. IBIS-AMI моделирование высокоскоростных интерфейсов памяти. В материалах 24-й конференции IEEE по электротехнике 2015 г. Performance of Electronic Packaging and Systems (EPEPS), Сан-Хосе, Калифорния, США, 25–28 октября 2015 г.; стр. 73–76.

3.

Комитет по стандартам LAN/MAN Компьютерного общества IEEE. Стандарт IEEE для Ethernet. 2012. Доступно онлайн: <https://ieeexplore.ieee.org/document/6419735> (последнюю на 26 июня 2024 г.).

4.

Ван Ю Ху, QS Оптимизация высокоскоростного последовательного канала на основе COM с использованием машинного обучения. IEICE Транс. Электрон. 2022, 105, 684–691. [\[Перекрестная ссылка\]](#)

5.

Гор, Б.; Ричард, М. Упражнение по применению эксплуатационного запаса канала (COM) для проектирования канала 10GBASE-KR. В материалах Международного симпозиума IEEE по электромагнитной совместимости (ЭМС) 2014 г., Роли, Северная Каролина, США, 4–8 августа 2014 г.; стр. 653–658.

6. Амбасана, Н.; Гоуп, Б.; Мутнури, Б.; Ананд, Г. Применение искусственных нейронных сетей для прогнозирования высоты/ширины/глаз на основе S-параметров. В материалах 23-й конференции IEEE по электрическим характеристикам электронных корпусов и систем, Портленд, Орегон, США, 26–29 октября 2014 г.; стр. 99–102.

7. Амбасана, Н.; Ананд, Г.; Мутнури, Б.; Гоуп, Д. Прогнозирование высоты/ширины/глаз на основе S-параметров с использованием моделей, основанных на обучении. IEEE Транс. Компон. Упаковки. Производитель Тех. нол. 2016, 6, 873–885. [\[Перекрестная ссылка\]](#)

8. Амбасана, Н.; Ананд, Г.; Гоуп, Д.; Мутнури, Б. Метод идентификации S-параметров и частот для глазных нейронных сетей Прогноз высоты/ширины IEEE Транс. Компон. Упаковки. Производитель Тех. нол. 2017, 7, 698–709. [\[Перекрестная ссылка\]](#)

9. Лу, Т.; Саң Дж; Ву, К.; Яң З. Моделирование высокоскоростных каналов с использованием методов машинного обучения для анализа целостности сигнала. IEEE Транс. Электромагн. Совместим. 2018, 60, 1957–1964. [\[Перекрестная ссылка\]](#)

10. Ло, Д.; Парк, Дж; Парк, Х.; Канг, Х.; Парк, С.; Ким, Дж Метод оценки ширины высоты/глаз на основе искусственной нейронной сети (ИНС) для USB 3.0. В материалах 27-й конференции IEEE по электрическим характеристикам электронных корпусов и систем (EPEPS) 2018 г., Сан-Хосе, Калифорния, США, 14–17 октября 2018 г.; стр. 209–211.

11. Саннес-Мисис, А.; Римоло-Донадио, Р.; Рой, К.; Сулейман, М.; Устер, К. Модели FNN для регрессии S-параметров в многослойных межсоединениях с различной электрической длиной. В материалах Латинской американской микроволновой конференции IEEE MTT-S 2023 г. (LAMC), Сан-Хосе, Калифорния, США, 6–8 декабря 2023 г.; стр. 82–85.

12. Ли, Х.; Ху, К. Моделирование каналов на основе машинного обучения для высокоскоростного последовательного канала. В материалах 6-й Международной конференции IEEE по компьютерам коммуникациям (ICCC) 2020 г., Чэнду, Китай, 11–14 декабря 2020 г.; стр. 1511–1515.

13. Тринеро, Р.; Канаверо, Ф. Г. Моделирование высоты/глазковой диаграммы в высокоскоростных линиях связи с помощью машиностроительных векторов. В материалах 22-го семинара IEEE по целостности сигналов и электропитанию (SPI) 2018 г., Брест, Франция, 22–25 мая 2018 г.; стр. 1–4.

14. Цао Ю; Чжаң QJ Новый подход к обучению робастному рекуррентному моделированию нелинейных цепей с помощью нейронных сетей. IEEE Транс. Микроу. Теория Тех. 2009, 57, 1539–1553. [\[Перекрестная ссылка\]](#)

15. Мутнури, Б.; Сваминатан, М.; Либос, Дж. П. Моделирование нелинейных драйверов цифрового ввода-вывода. IEEE Транс. Адв. Упаковки. 2006, 29, 102–113. [\[Перекрестная ссылка\]](#)

16. Цао Ю; Эрдин И.; Чжаң QJ Моделирование переходного поведения нелинейных драйверов ввода-вывода, объединяющих нейронные сети и эквивалентные схемы IEEE Микроу. Вирел. Компон. Летт. 2010, 20, 645–647. [\[Перекрестная ссылка\]](#)

17. ЮХ; Михалка, Т.; Ларби, М.; Сваминатан, М. Поведенческое моделирование настраиваемых драйверов ввода-вывода с предсказанием, включая шумисточника питания. IEEE Транс. Очень крупномасштабная интеграция. (СБИС) Сист. 2020, 28, 233–242. [\[Перекрестная ссылка\]](#)

18. ЮХ; Чаламаласетти, Х.; Сваминатан, М. Моделирование генераторов, управляемых напряжением, включая поведение ввода-вывода с использованием Дополненные нейронные сети. IEEE Access 2019, 7, 38973–38982. [\[Перекрестная ссылка\]](#)

19. Фараджи, А.; Нух, И. М.; Садросадат, С. А.; Мирвакили, А.; На, туалет; Фэн Ф. Глубокая рекуррентная нейронная сеть с пакетной нормализацией для макро моделирования высокоскоростных нелинейных цепей. IEEE Транс. Микроу. Теория Тех. 2022, 70, 4857–4868. [\[Перекрестная ссылка\]](#)

20. Мради, М.; Садросадат, А.; Дерхамми, В. Нейронные сети с длинной краткосрочной памятью для моделирования нелинейной электроники Компоненты IEEE Транс. Компон. Упаковки. Производитель Тех. нол. 2021, 1, 840–847. [\[Перекрестная ссылка\]](#)

21. Ли, З.; Ли, СХ; Ву, З. М.; Чу, Ю. М.; Дж. Ф. Суррогатное моделирование высокоскоростных каналов связи на основе GNN и RNN для обеспечения целостности сигнала Приложения. IEEE Транс. Микроу. Теория Тех. 2023, 71, 3784–7796. [\[Перекрестная ссылка\]](#)

22. Ло, Д.; Парк, Х.; Парк, С.; Ким, С.; Канг, Х.; Сим, Б.; Ким, С.; Парк, Дж; Чо, К.; Сонг, Дж; и другие. Модели глубоких нейронных сетей на основе характеристик канала для точной оценки глазковой диаграммы кремниевых интегральных схем с высокоскоростной памятью (HBM). IEEE Транс. Электромагн. Совместим. 2021, 64, 196–208. [\[Перекрестная ссылка\]](#)

23. Ли, Г. С.; Мо, СС; Чжао, WS Модель полуконтролируемой регрессии для оценки глазковой диаграммы кремниевых интегральных схем с высокой пропускной способностью памяти (HBM). В материалах симпозиума Международного общества прикладной вычислительной электромагнетизма 2023 года, Ханчжоу, Китай, 15–18 августа 2023 года; стр. 1–3.

24. Гоай, Швейцария; Ахмад, Н. С.; Го, П. Временные сверточные сети для моделирования переходных процессов в высокоскоростных каналах. Алекс. англ. Дж. 2023, 74, 643–663. [\[Перекрестная ссылка\]](#)

25. Ли, Б. В.; Цзяо, Б.; Чжоу, СН; Мейдер, Р.; Франзон, П. Каскадная модель глубокого обучения саморазвития для высокоскоростного приемника Приспособление. IEEE Транс. Компон. Упаковки. Производитель Тех. нол. 2020, 10, 1043–1053. [\[Перекрестная ссылка\]](#)

26. Ли, Б. В.; Цзяо, Б.; Чжоу, СН; Мейдер, Р.; Франзон, П. Адаптация CTLE с использованием глубокого обучения в высокоскоростном канале SerDes. В материалах 70-й конференции IEEE по электронным компонентам технологии м(ECTS), Орландо, Флорида, США, 3–30 июня 2020 г.; стр. 952–955.

27. Чжаң Х.Х.; Сюэ, З. С.; Лю, ХУ; Ли, П.; Цзян, Эл-Джей; Ши, генеральный директор Оптимизация высокоскоростного канала для обеспечения целостности сигнала с помощью Деер Генетический алгоритм. IEEE Транс. Электромагн. Совместим. 2022, 64, 1270–1274. [\[Перекрестная ссылка\]](#)

28. Шаң Г.; Ли, Г.; Ван Ю; Син К.; Чжоу, Ю. Яң Ю Применение и перспектив методов искусственного интеллекта в прогнозировании целостности сигналов и оптимизации микросистем. Микромашины 2023, 14, 344. [\[CrossRef\]](#)

29. Меллиц, Р.; Раң А.; Хромат; Рагавассами, В. Операционная маржа канала (COM): эволюция характеристик каналов для 25 Гбит/с и выше. В материалах DesignCon 2013, Санга-Клара, Калифорния, США, 28–31 января 2013 г.

30. Пу, Б.; Он Дж; Хармон, А.; Го, Ю. Лю, Ю. Цай, К. Методология проектирования целостности сигнала для корпуса в комплексной оптике на основе показателя качества как рабочего запаса канала. В материалах Международного совместного симпозиума EMC/SI/PI и EMC Europe 2021 IEEE, Роли, Северная Каролина, США, 26 июля – 13 августа 2021 г.; стр. 492–497.

31. Маккалок, В. С.; Питтс, В. Логическое исчисление идей, имманентных нервной деятельности. Бк. Математика. Биофиз. 1943, 5, 115–133. [\[Перекрестная ссылка\]](#)

32. Боно, FM; Радичони, Л.; Чинквемани, С. Новый подход к контролю качества автоматизированных производственных линий, работающих под Крайне противоречивые условия. англ. Прил. Артиф. Интел. 2023, 122, 106149. [\[CrossRef\]](#)
33. Сталь, РГД; Торри, Дж Х. Принципы процедуры статистики; МакГроу Хилл: Нью-Йорк, Нью-Джерси, США, 1960 г.
34. Гириш, Р. Фаст R-CNN. В материалах Международной конференции IEEE по компьютерному зрению (ICCV), Сантьяго, Чили, 7–13 декабря 2015 г.; стр. 1440–1448.
35. Кингма, ДП; Ба, Дж Адам: Метод стохастической оптимизации. arXiv 2014, arXiv:1412.6980.
36. Васвани А.; Шазир, Н.; Пармар, Н.; Ушкорейт, Дж; Джонс, Л.; Гомес, АН; Кайзер, Л.; Полосухин ИИ. Внимание – это все, что вам нужно. В Proceedings of the Advances in Neural Information Processing Systems, Лонг-Бич, Калифорния, США, 4–9 декабря 2017 г.; стр. 6000–6010.
37. Акиба, Т.; Саню, С.; Янасе, Т.; Окта, Т.; Кояма, М Огуна: Структура оптимизации гиперпараметров следующего поколения. В материалах 25-й Международной конференции ACM SIGKDD по обнаружению знаний и интеллектуальному анализу данных, Анкоридж, штат Алабама, США, 4–8 августа 2019 г.
38. Фрейзер, П.И. Учебное пособие по байесовской оптимизации. arXiv 2018, arXiv:1807.02811.

Отказ от ответственности/Примечание издателя : Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.

Статья

Улучшение восприятия автономного транспортного средства в неблагоприятных погодных условиях:

Многоцелевая модель для интегрированной классификации погоды и обнаружения объектов

Нассер Алуфи *, Абдулазиз Альнори и Абдулла Басухайль

Департамент компьютерных наук, факультет вычислительной техники и информационных технологий, Университет короля Абдель Азиза, Джидда, 21589, Саудовская Аравия; asalnori@kau.edu.sa (AA); abasuhail@kau.edu.sa (AB)

* Переписка: nhassanaloufi@stu.kau.edu.sa.

Аннотация: Надежное обнаружение объектов и погодная классификация необходимы для безопасной эксплуатации автономных транспортных средств (AB) в неблагоприятных погодных условиях. Хотя существующие исследования часто рассматривают эти задачи отдельно, в данной статье предлагается новая многоцелевая модель, которая рассматривает классификацию погоды и обнаружение объектов как единую задачу с использованием только системы обнаружения AV-камеры. Наша модель обеспечивает повышенную эффективность и потенциальный прирост производительности за счет интеграции оценки качества изображения, генеративно-состязательной сети сверхвысокого разрешения (SRGAN) и модифицированной версии You Only Look Once (YOLO) версии 5. Кроме того, за счет использования сложной функции обнаружения в неблагоприятных погодных условиях. Набор данных Nature (DAWN), который включает в себя четыре типа суровых погодных условий, включая часто упускаемую из виду песчаную погоду, мы применили несколько методов дополнения, что привело к значительному расширению набора данных с 1027 изображений до 2046 изображений. Кроме того, мы оптимизируем архитектуру YOLO для надежного обнаружения шести классов объектов (автомобиль, велосипедист, пешеход, мотоцикл, автобус, грузовик) в неблагоприятных погодных условиях. Комплексные эксперименты демонстрируют эффективность нашего подхода, достигая средней средней точности (mAP) 74,6%, подчеркивая потенциал этой многоцелевой модели для значительного улучшения возможностей восприятия камер автономных транспортных средств в сложных условиях.



Цитирование: Алуфи, Н.; Алнори, А.; Басухайль, А. Улучшение восприятия автономных транспортных средств в неблагоприятных погодных условиях: многоцелевая модель для интегрированной классификации погоды и обнаружения объектов. Электроника 2024, 13, 3063. <https://doi.org/10.3390/electronics13153063>

Академические редакторы: Шипинг Вэнь и Цзянин Сяо

Поступила: 14 мая 2024 г.
Пересмотрено: 22 июля 2024 г.
Принято: 29 июля 2024 г.
Опубликовано: 2 августа 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/>).

Ключевые слова: автономные транспортные средства; обычная нейронная сеть; обнаружение объектов; глубокое обучение; датчики камеры; неблагоприятная погода; классификация погоды

1. Введение

Быстрое развитие технологии беспилотных транспортных средств (AV) привлекло внимание исследователей, инженеров, политиков и общественности. Центральное место в разработке AV занимают датчики, которые обеспечивают восприятие и принятие решений в динамичной среде вождения. Среди них датчики камеры играют жизненно важную роль в качестве основного источника визуального восприятия в AV-системах. Камеры в режиме реального времени снимают изображения с высоким разрешением окружающей среды автомобиля, предоставляя важные визуальные данные для точного обнаружения и классификации различных объектов. Используя передовые алгоритмы обнаружения объектов, камеры способствуют различным AV-функциям, таким как удержание полосы движения и планирование маршрута, путем постоянного мониторинга разметки полосы движения и изменений в планировке дороги. Это позволяет транспортному средству сохранять свое положение в пределах полосы движения и принимать обоснованные решения относительно траектории движения и маневрирования, тем самым повышая общую безопасность дорожного движения и транспортный поток. Кроме того, датчики камеры способствуют планированию пути, определяя препятствия, дорожные знаки и другие объекты, позволяя транспортному средству соответствующим образом адаптировать свою траекторию и ориентироваться в сложных сценариях дорожного движения.

Оценка глубины — еще одна ключевая возможность датчиков камеры, позволяющая AV точно воспринимать расстояния до окружающих объектов. Благодаря передовым технологиям обработки изображений камеры могут обеспечивать восприятие глубины, улучшая пространственное восприятие автомобиля и возможности обхода препятствий. Сегментация изображения — это дополнительная задача, выполняемая

способность осознания и обхода препятствий. Сегментация изображения — это дополнительная задача, выполняемая сенсорами камеры, при которой визуальная сцена сегментируется на семантически значимые области. Эта сегментация позволяет AV различать различные датчики камеры, при этом визуальная сцена сегментируется на семантически значимые части.

множество элементов в поле зрения, что облегчает надежное обнаружение и классификацию объектов, регионов. Эта сегментация позволяет AV различать различные элементы внутри

необходим для безопасного судоходства. Более того, датчики камер играют решающую роль в объединении поля зрения, обеспечивая надежное обнаружение и классификацию объектов, что важно для

безопасного восприятия навигации, объединения данных с нескольких камер, расположенных вокруг автомобиля, для объединения. Более того, сенсоры камер играют решающую роль в описании восприятия, объединяя

составить комплексную картину окружающей среды для создания целостной картины, улучшает данные автомобиля с нескольких

понимание окружающей среды, основываясь на видеопотоках, полученных от нескольких камер, расположенных вокруг автомобиля, улучшает данные автомобиля с нескольких

Помимо этого, сегментация изображений также используется для обнаружения пешеходов, велосипедистов, других транспортных средств и объектов в окружающей среде.

предоставляет важные наблюдения за поведением и статусом пассажиров. На рисунке 1 перечислены основные роли поведения и статуса пассажиров. На рис . 1 перечислены основные роли камер и их системы в AV. Системы в AV.




Рисунок 1. Основные роли камер в AV.

В дополнение к своим основным функциям камеры предлагают экономичное и легкое устройство. В дополнение к своим основным функциям камеры предлагают экономичное и легкое решение по сравнению с альтернативными сенсорными технологиями, такими как LiDAR и радар. Этот весовое решение по сравнению с альтернативными сенсорными технологиями, такими как LiDAR и радар, ценная доступность способствует широкому внедрению и внедрению AV-технологий, открывая путь Эта доступность способствует широкому внедрению и внедрению AV-технологий, прокладывая путь к будущему, в котором все участники дорожного движения будут повсеместно встречаться на наших дорогах. Прокладывая путь к будущему, в котором все участники дорожного движения будут повсеместно встречаться на наших дорогах.

Разработкой и реализацией проекта по внедрению системы видеонаблюдения, достигаются высочайший уровень АУ, округления среды при всех условиях и сценариях, не менее 1 млн человек разобрались, что такое видеонаблюдение, и в результате, в среднем, в среде видеонаблюдения, каковы объекты в своем поведении. Достичь этого уровня по-прежнему очень сложно, во время неблагоприятных погодных условий, которые окружают окружающую среду при любых условиях и сценариях, не менее чем похожее на человеческое, представляет собой серьезную проблему для датчиков камер, влияя на их способность захватывать четкие изображения. поведение. Достичь этого уровня по-прежнему очень сложно при неблагоприятных погодных условиях, что требует надежных изображений окружающей среды. Погодные условия, такие как дождь, снег, туман и представляют собой серьезные проблемы для датчиков камер, влияя на их способность снимать ясные песчаные бури, что создает серьезные проблемы для датчиков камер, и ключевые проблемы включают в себя: и достоверные изображения окружающей среды. Погодные условия, такие как дождь, снег, туман и • Ограниченная видимость: неблагоприятные погодные условия часто приводят к ухудшению видимости, ухудшение песчаных бурь создают серьезные проблемы для датчиков камер, а ключевые проблемы включают в себя: повышение эффективности датчиков камер при захвате четких изображений окружающей среды.

- **Ограничения видения в условиях: неблагоприятные погодные условия могут вызвать быстрое ухудшение качества изображения с камерами при получении четких изображений окружающей среды:**
 - Капли воды и скопление снега на объектах могут закрывать поле зрения, затмевая его или скопляясь снегом на объективах камеры, что приводит к искажению, размытию или окклюзии.
 - Капли воды и скопление снега: дождь и снег могут привести к невозможности обнаружения и распознавания капель воды.
- или скопление снега на объективах камеры, что приводит к искажению, размытости или окклюзии.
 - Туман и дымка: туманные условия создают туманную атмосферу, которая снижает контрастность и обрабатывает захваченные изображения. Это накопление может ухудшить качество изображения и снизить четкость изображений с камеры, затрудняя обнаружение и локализацию объектов. Наличие возможности обнаружения и распознавания объектов.
- Туман и дымка создают неустойчивую атмосферу, которая снижает контрастность и ставит под угрозу **отсутствие близкого изображения, которое может быть обнаружено или описано объектом.**
 - Близкие и изгибающиеся изображения трудно различать, так как объекты, находящиеся вдали, могут выглядеть как важные детали, что ставит под угрозу надежность систем AV-восприятия.
- AVs для безопасной навигации в неблагоприятных погодных условиях.
 - Близки и отражения: могут возникнуть блики от мокрых дорожных покрытий или отражающих поверхностей.
 - Частицы песка и пыли: песчаные бури и пыльные условия могут привести к накоплению отражения на изображениях с камеры, приводящие к переэкспонированию или размытию изображений. Частицы песка и пыли на объективах фотокамер закрывают поле зрения и ухудшают качество изображения. Блики и отражения могут скрывать важную визуальную информацию, ухудшая качество изображения. Такое скопление частиц может поставить под угрозу производительность датчиков камеры, влияющие на надежность систем AV-восприятия.
- **Динамические условия освещения:** неблагоприятные погодные условия могут вызвать быстрые изменения
 - Динамические условия освещения: неблагоприятные погодные условия могут вызвать быстрые изменения яркости, контрастности и цветовой температуры в окружающей среде, что может привести к окклюзии объектов, что ставит под угрозу восприятие окружающей среды.
- Динамические условия освещения: неблагоприятные погодные условия могут вызвать быстрые изменения
 - Динамические условия освещения: неблагоприятные погодные условия могут вызвать быстрые изменения яркости, контрастности и цветовой температуры.

Системы камер должны адаптироваться к этим динамическим условиям освещения, чтобы поддерживать точное восприятие окружающей среды и обеспечивать надежное обнаружение и распознавание объектов. Калибровка датчика: неблагоприятные погодные условия могут потребовать настройки камеры. Калибровка датчика: неблагоприятные погодные условия могут потребовать настройки камеры.

- Калибровка датчика. Неблагоприятные погодные условия могут потребовать настройки камеры.

параметры калибровки для компенсации изменений освещенности, видимости и параметры калибровки каждого датчика для компенсации изменений освещенности, видимости и датчика

форма. Обеспечение точной калибровки датчика имеет важное значение для поддержания надежности

качество и эффективность сенсоров камеры в неблагоприятных погодных условиях.

Надежность и прочность: неблагоприятные погодные условия обеспечивают надежность и надежность проблемы для датчиков камер, требующие от них продолжения эффективного функционирования в суровых условиях окружающей среды. Обеспечение долговечности и устойчивости камеры к

Датчики температуры, решающие значение для безопасной и надежной работы безаварных летательных аппаратов, являются типичными представителями изделий, работающих в экстремальных условиях.


На рисунке 2 показаны некоторые проблемы обнаружения объектов в неблагоприятных погодных условиях. Каждый тип погоды имеет свои прятатся. Например, во время сильного снегопада и песчаных бурь дорожные дорожки дороги могут быть не видны. В дождь капли воды на границах камеры могут быть скрыты объектами, приводя к искажению результатов распознавания. Вывод: в реальных условиях обнаружения объектов в неблагоприятных погодных условиях является проблемой.



(a)



(b)



(c)



(d)



(e)



(f)

[illegible][illegible]

С моделью YOLO инкрементально вносились изменения, которые обнаруживали за собой приход к CNN. YOLOv2 и последующие итерации не сформировали единой архитектуры, а каждая итерация проходила под названием Darknet-53 в архитектуре. Тогда вышла новая версия YOLO под названием YOLOv4. Через CNN, YOLOv2 и последующие итерации, такие как YOLOv3 [8], представили предлагаемую цель для улучшения архитектуры. Новая версия YOLOv4 имела более высокие значения предельной точности, чем YOLOv3 [9] и YOLOv2 были более поздними версиями. Из-за точности и скорости, а также заметных результатов, фактор YOLO

Другая модель, называемая мультитиковым детектором Single-Shot (SSD), предложенная в [10], улучшения по сравнению с предшественниками. YOLOv5, YOLOv7 [9] и YOLOv8 были позже итерированы и достигли конкурентоспособных результатов на наборе данных VOC2007 с улучшениями mAP. Акции YOLO: другая модель, называемая мультитиковым детектором Single-Shot (SSD), предложенная в этой статье, наша цель — предложить решение для AV-систем на основе датчиков камеры, которые [10] добились конкурентоспособных результатов на наборе данных VOC2007, благодаря улучшениям, дающим не только обнаруживать объекты, но и классифицировать погоду на основе состояний сцен

Объем нашей статьи показан на рисунке 3.



В [12] авторы рассматривают проблемы, с которыми сталкиваются ЛА при неблагоприятных погодных условиях, где типичные модели восприятия испытывают трудности. Существующие исследования в основном сосредоточены на классификации погодных условия; однако авторы изучали переходы между этими типами

погода. Они предложили метод определения и понимания шести промежуточных состояний перехода погоды (от облачности к дождю, от дождя к облачности, от солнечного к дождливому, от дождливого к солнечному, от солнечного к туманному и от туманного к солнечному). Этот подход включает в себя интерполяцию промежуточных данных о переходе погоды с использованием вариационного автоэнкодера, извлечение пространственных характеристик с помощью очень глубоких сверточных сетей VGG (Visual Geometry Group) и моделирование временного распределения с помощью закрытого рекуррентного блока для классификации. Авторы предложили новый крупномасштабный набор данных под названием AIWD6 (Вожделение в неблагоприятную промежуточную погоду), и результаты показали эффективную модель изменения погоды.

В [13] авторы представляют новую структуру под названием WeatherNet, которая использует четыре глубокие модели CNN на основе архитектуры ResNet50. WeatherNet автономно извлекает информацию о погоде из входного изображения и классифицирует выходные данные по нужной категории. Однако недостатком представленного фреймворка является невозможность совместного использования функций, поскольку четыре модели работают отдельно.

Ссылка. В [14] основное внимание уделяется значительному влиянию неблагоприятных погодных условий на городское движение и подчеркивается важность распознавания погодных условий для таких приложений, как AV-помощь и интеллектуальные транспортные системы. Используя достижения в области глубокого обучения, в документе представлена новая упрощенная модель под названием ResNet15, предлагаемая версия знаменитого ResNet50 [15]. Предлагаемая модель имеет полносвязный слой, в котором используется классификатор Softmax. В документе также представлен новый набор данных под названием «WeatherDataset-4», содержащий около 5000 изображений, охватывающих туманную, дождливую, снежную и солнечную погоду. Хотя предлагаемая сеть превзошла традиционную ResNet50, в статье не хватает покрытия в ночное время и в песчаных районах.

В [16] авторы предложили алгоритм MCS-YOLO для улучшения обнаружения объектов за счет интеграции механизма координатного внимания, многомасштабной структуры для небольших объектов и применения структуры Swin Transformer [17]. В ходе экспериментов с набором данных BDD100K они продемонстрировали среднюю точность (mAP) 53,6%.

Статья [18] является одной из первых работ, в которых CNN применялась для AV-классификации погоды. Авторы добавили два полностью связанных слоя для извлечения объектов из изображений условий дорожного обслуживания (RSC). В статье основное внимание уделялось условиям зимних дорог, где проблема заснеженных дорог была разделена на три эксперимента: (а) классификация по двум классам, (б) классификация по трем классам и (в) классификация по пяти классам. Модель превзошла традиционные методы классификации и показала точность 78,5% при применении классификации по пяти классам.

В [19] YOLOv4 был усовершенствован для обнаружения объектов за счет предложения головки без якоря и отделенной связи. В документе использовался BDD100k в качестве исходного набора данных и была создана новая версия, ориентированная на три типа погоды (дождь, снег, туман). Результаты эксперимента показали, что mAP составляет 60,3%.

В [20] авторы извлекли высокоточные данные о движении и предложили новый механизм отслеживания транспортных средств под названием SORT++. Адаптивный к изображению YOLO (IA-YOLO) был представлен в [21] и показал улучшение обнаружения объектов в условиях низкой освещенности и тумана.

Ссылка. [22] предложили сеть с двумя подсетями (DSNet) для обнаружения объектов и достигли показателя mAP 50,8% в туманную погоду. В [23] YOLOv5 исследовался для обнаружения объектов нескольких классов, и mAP всех классов набрал 25,8%. В [24] изображения дронов были созданы и применены к модифицированной версии YOLOv5, показатель mAP которой составил около 50%.

В статье [25] сравнивались характеристики YOLOv3, YOLOv4 и Faster R-CNN в разные типы погоды (дождливая, туманная, снежная). В документе сделан вывод, что YOLOv4 превзошел YOLOv3 и Faster R-CNN.

В таблице 1 представлена сводка последних публикаций по классификации погоды и обнаружению объектов в AV-среде. В то время как стандартные модели обнаружения объектов в первую очередь фокусируются исключительно на процессе обнаружения, наша работа и предлагаемая модель имеют несколько ключевых отличий по сравнению с недавними соответствующими исследованиями. Во-первых, мы включили в нашу модель новый этап под названием «Блок качества», предназначенный для оценки и улучшения наблюдаемой сцены. Во-вторых, мы добавили регулируемый пороговый показатель, чтобы уменьшить количество изображений, входящих в фазу улучшения. В-третьих, наше исследование уникально касается песчаных погодных условий, которые не рассматривались в последних публикациях.

Таблица 1. Последние публикации в области АВ исключают песчаную погоду из своих исследований. Более того, существует пробел в сочетании классификации погоды и обнаружения объектов.

Бумага	Погода Классификация	Объект Обнаружение	Въехать Снег	Въехать Дождь	Въехать Туман	Въехать Песок
[11]		x				x
[13]		x			x	x
[14]		x				x
[16]	x					x
[18]		x		x	x	x
[19]	x					x
[20]	x				x	x
[21]	x		x	x		x
[22]	x		x	x		x
[23]	x		x		x	x
[24]	x				x	x
[25]	x					x
Наш						

3. Методология

Наша методология разработки модели, способной как классифицировать погоду, так и Обнаружение объектов в суровую погоду началось с применения Обнаружения в неблагоприятной погоде Природа (DAWN) набор данных [26]. Мы сосредоточились на четырех основных типах погоды (песчаная, дождливая, туманная, и снежный) с шестью классами (пешеход, велосипед, автомобиль, мотоцикл, автобус и грузовик). Расширять набор данных и представить новый вариант существующих изображений, мы включили данные расширение в нашей работе. Этот расширенный набор данных был объединен с исходным набором данных DAWN. dataset для увеличения количества обучающих выборок. Полное описание аугментации будет представлен в разделе 6. Затем мы разделили объединенный набор данных на обучающий и наборы валидации. Наш процент разделения составляет 80% изображений для обучения, тогда как (20%) были используется для валидации и тестирования (10% для валидации и 10% для тестирования). Тренировочный набор использовался для обучения моделей классификации погоды и обнаружения объектов, а набор проверки сыграл решающую роль в предотвращении переобучения. После этого этапы оптимизации участвуют в поиске наилучшей производительности модели путем изменения гиперпараметров. Наконец, мы оценили оптимизированные модели, используя стандартную среднюю точность. (mAP), показатели точности и полноты. На рисунке 4 показана последовательность нашей методологии.




Рисунок 4. Последовательность применения нашей методологии в этой статье.

Чтобы оптимизировать эффективность вычислений при ограниченных ресурсах графического процессора, мы использовали облачную платформу Colab от Google в качестве нашей экспериментальной среды. Colab предоставляет платформу машинного обучения Tesla P40 и высокопроизводительные графические процессоры (например, Tesla T4). С помощью Colab мы смогли эффективно проводить наши эксперименты, в частности, с интеграцией с CUDA (унифицированная архитектура вычислительных устройств), которая помогает в ускорении вычислительного процесса нашего конвейера и части CNN при обнаружении объектов (особенно в таких задачах, как свертка, объединение, нормализация и уровни активации).

Для количественной оценки эффективности моделей обнаружения объектов доступны различные показатели. В нашей статье мы отдали приоритет трем основным показателям: (а) средняя средняя точность (mAP), (б) точность и (в) полнота. mAP является распространенным показателем оценки в

вычислительный процесс нашего конвейера и части CNN при обнаружении объектов (особенно в таких задачах, как свертка, объединение, нормализация и уровни активации).

Для количественной оценки эффективности моделей обнаружения объектов доступны различные показатели. В нашей статье мы отдали приоритет трем основным показателям: (а) средняя средняя точность (mAP), (б) точность и (в) полнота. mAP выступает в качестве распространенной метрики оценки в области объекта.

обнаружение, предлагающее целостную оценку навыков модели в идентификации объектов и локализация. mAP сочетает в себе точность и полноту, вычисляя среднюю точность (AP) для каждого класса или категории объектов с последующим определением среднего значения по всем классам. AP служит мерой качества обнаружения, инкапсулируя как точность, так и точность идентифицированные объекты и полнота обнаружения на месте происшествия. Через вычисление mAP, производительность нашего конвейера можно численно сравнить и оценить по различным домены и сценарии.

Мы также считали точность и полноту незаменимыми показателями в контексте обнаружение объекта. Точность — это доля или процент извлеченных элементов, которые относится к правильному классу, тогда как припоминание измеряет процент релевантных объектов, которые успешно получен. Прецизионность выражается как отношение истинных положительных результатов (TP) к сумме истинных срабатываний и ложных срабатываний (FP), представленных как:

Точность = TP/(TP + FP)

Напомним, это отношение TP к сумме истинных положительных и ложных отрицательных результатов (FN), представленное как:

Напомним = TP/(TP + FP)

4. Набор данных

Для набора данных, как мы упоминали ранее, мы использовали DAWN в нашей разработке и экспериментирование. Набор данных DAWN охватывает четыре типа неблагоприятных погодных условий: песчаную бурю, дождь, снег и туман. На рисунке 5 показаны примеры различных типов погоды, описанных в РАССВЕТ. Набор данных содержит 1027 изображений, охватывающих четыре типа погоды и различные экологические контексты, такие как автомагистрали, автостреды и городские ландшафты, обеспечивая широкое представление сценариев реального мира.

Электроника 2024, 13, х НА ЭКСПЕРТИЗУ

из 24



Рисунок 5. Набор данных DAWN представляет различные суровые погодные условия, такие как туман, дождь, снег и песок [26].

Однако, другие наборы данных охватывают неблагоприятные погодные условия, набор данных DAWN имеет преимущество включения изображений песчаной бури или песчаной погоды, которые часто отсутствуют из других наборов данных. Эта уникальная особенность DAWN позволила нашей модели обеспечить классификацию погоды и обнаружение объектов в различных типах географических сред. Используемый набор данных DAWN изначально состоит из 1027 изображений размером 640 × 640.

Аннотация изображения содержит класс объекта и соответствующие границы: x, y, ширину и высоту ограничивающего прямоугольника (x_center, y_center, ширину, высоту). Инжир-

Figure 1 displays six images showing various vehicles (cars, trucks) in different scenes (rainy street, parking lot, highway) with bounding boxes and labels. The labels are 'Car' and 'truck'.

5. Предлагаемая модель

«Эксперименты и результаты». Стоит отметить, что в методе BRISQUE, как правило,

«Эксперименты и результаты». Стоит отметить, что в методе BRISQUE, как правило, более низкий балл указывает на лучшее качество восприятия, а более высокий балл BRISQUE указывает на ухудшение качества восприятия. Алгоритм BRISQUE имеет ряд преимуществ, которые сделали его подходящим решением для нашей модели и для оценки неблагоприятных погодных условий. Во-первых, эта метрика качества изображения без эталона, поскольку для нее не требуется идеальное эталонное изображение. Сравнение. Это очень выгодно в неблагоприятных погодных условиях, когда получение идеальных, неискаженных изображений может оказаться сложной задачей, если не невозможной. BRISQUE функционирует благодаря анализу статистики естественной сцены (NSS) изображения и сравнению ее с ожидаемой статистикой естественных (неискаженных) изображений. Любые отклонения от этой естественности являются помечены как индикаторы ухудшения качества, что делает их удобными для выявления видов искажения, вносимые погодными явлениями. Кроме того, BRISQUE предлагает вычислительные эффективность по сравнению с некоторыми другими вариантами, что может быть важно при работе с большими наборами данных изображений или в сценариях, где требуется оценка качества в реальном времени. Для На этапе улучшения изображения мы использовали генеративно-состязательную технологию суперразрешения. Сетевая технология (SRGAN) [28], состоящая из генераторной и дискриминаторной сетей. Сеть генератора предназначена для повышения качества изображений с низким разрешением, а дискриминатор Сеть направлена на улучшение выходных данных генератора, что приводит к повышению четкости изображения. После блока качества изображение обрабатывается двумя сетями YOLOv5. Один YOLO Сеть, тщательно обученная на наборе данных изображений с метками погоды, точно классифицирует погодные условия, такие как песчаный, дождливый, снежный или туманный. Одновременно с этим отдельный

- Повышение устойчивости модели к факторам влияния вида внешнего вида объекта, таким как изменение освещения, отражений или шумов и т.д. (в частности, для задачи зрения).
- Устранение классового дисбаланса путем избыточной или заниженной выборки классов меньшинств. Большинство.
- Смягчение переобучения путем введения регуляризации и шума в обучающие данные. В следующих разделах описаны дополнения, которые мы выполнили в этой статье.

- Устранение классового дисбаланса путем избыточной или заниженной выборки классов меньшинств. большинство.
- Смягчение переобучения путем введения регуляризации и шума в обучающие данные.

В следующих разделах описаны дополнения, которые мы выполнили в этой статье.

6.1. Вращение

Это используется для представления объекта с разных углов обзора. В реальных сценариях объекты могут появляться под разными углами или поворотами, и добавление этого в наше дополнение может помочь модели лучше обрабатывать эти варианты представления.

6.2. Хюэ

Ние — это метод улучшения изображения на основе цвета, который изменяет оттенок или цветовой тон изображения. изображение, сохраняя при этом его яркость и насыщенность.

6.3. Шум

Мы также включили синтетический шум в наш процесс расширения, чтобы расширить наш набор данных. Этот тип дополнения повышает устойчивость нашей модели к шуму и расширяет ее способность адаптироваться к новым данным или сценариям.

6.4. Насыщенность

Насыщенность регулирует интенсивность цветов изображения. Насыщая изображение, мы эффективно масштабируем значения пикселей на случайный коэффициент в пределах заданного диапазона. Увеличение значения насыщенности изображения может сделать цвета более яркими и яркими, а его уменьшение может сделать цвета более приглушенными и приглушенными. Мы увеличили насыщенность нашего набора данных примерно на 25%.

6.5. Оттенки серого

Мы включили функцию увеличения оттенков серого, которая преобразует изображение в оттенки серого. Этот метод обычно используется для увеличения контрастности изображения и улучшения его деталей.

6.6. Яркость.

Случайным образом увеличивая яркость изображений, мы подвергли нашу модель воздействию более широкого диапазона условий освещения, тем самым повысив ее устойчивость к изменениям освещенности. Мы увеличили изображения, сделав их примерно на 15 % ярче.

6.7. Размытие

Размытие используется для придания изображениям эффекта расфокусировки. Для наших дополненных данных мы использовалось размытие по Гауссу до 1,25 пикселей.

6.8. Контакт

Кроме того, мы искусственно изменили уровень экспозиции изображений, установив его в диапазоне от 10% до 10%.

6.9. Вырезать

Мы также вырезали небольшие части объектов в сцене. Целью этого является добавление окклюзии к нашему эксперименту, которая заключается в блокировании, закрытии или затемнении объекта от поля зрения камеры.

В таблице 2 показаны значения настроек аугментации и их влияние на изображения.

Таблица 2. Краткое описание примененных дополнений и их влияние на изображение.

Увеличение	Ценить	Влияние
Вращение	90 градусов	Помогает модели быть нечувствительной к ориентации камеры.
Хюэ	15%	Случайная регулировка цветов
Шум	Случайный шум	К изображению добавлено больше препятствий

Таблица 2. Продолжение.

Увеличение	Ценить	Влияние
Насыщенность	25%	Изменяет интенсивность пикселей
Оттенки серого	15%	Преобразует изображение в одноканальное
Яркость	15%	Изображение кажется светлее
Размытие	1.25px	Усредняет значения пикселей с соседними
Контакт	10%	Устойчивость к изменениям освещения и настроек камеры.
Вырезать	Вырезать произвольные части изображения	Более устойчив к обнаружению полубъектов

7. Эксперименты и результаты.

Чтобы протестировать нашу модель, мы провели несколько экспериментов, начиная с установки набора Пороговый балл BRISQUE — 42,75. Эта оценка является средней оценкой качества для DAWN. набор данных, и любое изображение выше этого среднего балла пройдет стадию улучшения.

Таблица 3 объясняет причину выбора 42,75 в качестве нашей пороговой точки и иллюстрирует влияние на качество изображения путем измерения показателей BRISQUE до и после аугментации. В таблице сравниваются изображения из набора данных DAWN (песчаные бури, дождь, снег и туман) с нашими расширенные дополненные изображения того же набора данных с целью имитации неблагоприятной погоды условия. При любых погодных условиях дополненные изображения обычно демонстрируют более высокую Оценки BRISQUE, указывающие на снижение качества изображения по сравнению с исходным DAWN. изображений. Как видно из таблицы, дополненные изображения хуже примерно на 9%, когда речь идет о среднее качество сцены. Такое низкое качество дополненных изображений можно объяснить выполненные улучшения (размытие, оттенок, насыщенность, шум, обрезка, яркость и экспозиция), которые являются обычными последствиями при неблагоприятной погоде. Наблюдаемые различия подчеркивают важность разработки модели оценки качества для сохранения качества изображения, особенно в неблагоприятных погодных условиях, когда четкость изображения имеет решающее значение для точного наблюдения за происходящим и обнаружение объектов.

Таблица 3. Сравнение качества изображения с аугментацией и без нее. Результаты показывают среднее качество изображения 46,59 для расширенного набора данных DAWN по сравнению с 42,75 для исходного. Набор данных DAWN.


	Сэнди	Туманно	Снежно	Дождливый	Средний
РАССВЕТ изображения	44,05	45,21	40,18	41,57	42,75
Показатель качества					
Дополненные изображения DAWN	48,71	49,83	43,19	44,64	46,59
Показатель качества					

Экспериментальный сценарий для расширенного набора данных DAWN был реализован в рамках Среда Google Colab, использующая вычислительную мощность графического процессора Tesla T4. Мы внесли несколько изменений в архитектуру YOLOv5, стремясь создать подходящую модель для нашего домена. Данная модификация включает в себя изменение функций активации и протестируйте модель с помощью функций SiLU и LeakyRelu. Мы также изменили основу и отправляйтесь тестировать производительность архитектур BottleneckCSP и C3. Кроме того к этому гиперпараметры, такие как эпохи и размер пакета, были изменены повсюду. наши эксперименты.

После разработки нашей модели мы приступили к экспериментальной фазе, реализовав BottleneckCSP как опорная и головная архитектура. Наша модель продемонстрировала многообещающие результаты, достигая средней средней точности (mAP) 55,6% и 45,6% при обучен в течение 128 эпох с размером пакета 32, используя активацию SiLU и LeakyReLU. функции соответственно. Из таблицы 4 хорошо видно, что при реализации Узкое местоCSP в нашей модели: mAP увеличивалось для функций SiLU и LeakyRelu. всякий раз, когда мы увеличивали количество эпох. Также видно, что LeakyRelu имеет более низкую производительность, чем у SiLU с магистралью и головкой BottleneckCSP. В таблице 4 показаны полные результаты нашей модели с использованием BottleneckCSP.

Функция активации позвоночника и головы		Эпоха	Партия	карта
Узкое местоCSP	СИЛУ	32	16	33,7%
Узкое местоCSP	СИЛУ	32	32	34,5%
Узкое местоCSP	СИЛУ	64	16	40,2%
Узкое местоCSP	СИЛУ	64	32	43,9%
Узкое местоCSP	СИЛУ	128	16	55,2%
Узкое местоCSP	СИЛУ	128	32	55,6%
Узкое местоCSP	ДырявоеРелу	32	16	24,0%
Узкое местоCSP	ДырявоеРелу	32	32	25,1%
Узкое местоCSP	ДырявоеРелу	64	16	34,7%
Узкое местоCSP	ДырявоеРелу	64	32	34,9%
Узкое местоCSP	ДырявоеРелу	128	16	38,7%
Узкое местоCSP	ДырявоеРелу	128	32	45,6%

Электроника 2024. 13. х НА ЭКСПЕРТИЗУ



Позвоночник и голова	Функция активации	Эпоха	Партия	карта
СЗ	СИЛУ	32	16	71,8%
СЗ	СИЛУ	32	32	68,6%

Таблица 5. Производительность нашей модели с использованием СЗ в качестве основы и головы.

Функция активации позвоночника и головы		Эпоха	Партия	карта
СЗ	СиЛУ	32	16	71,8%
СЗ	СиЛУ	32	32	68,6%
СЗ	СиЛУ	64	16	74,6%
СЗ	СиЛУ	64	32	74,1%
СЗ	СиЛУ	128	16	74,0%
СЗ	СиЛУ	128	32	73,1%
СЗ	ДырявоеРелу	32	16	64,4%
СЗ	ДырявоеРелу	32	32	67,1%
СЗ	ДырявоеРелу	64	16	62,9%
СЗ	ДырявоеРелу	64	32	63,2%
СЗ	ДырявоеРелу	128	16	72,9%
СЗ	ДырявоеРелу	128	32	72,4%

Электроника 2024, 13, х НА ЭКСПЕРТИЗУ

14 из 21





Рисунок 10. Оценка F1 и mAP при 0,5:0,95 нашей модели после 64 эпох.

Результаты таблицы, Таблицы 4 и 5, подчеркивают **примечательное** увеличение количества эпох, не всегда коррелирует с более высоким средним значением. Наша модель достигла своего пика на 64 эпоху, что является важным фактором для выбора mAP при обучении в течение 64 эпох, а не 128 эпох, вопреки первоначальному ожиданию. Этот вывод подчеркивает важность тщательной проверки и адаптации гиперпараметров и архитектуры моделей. Проведение дополнительных экспериментов для определения наиболее эффективной архитектуры для обучения для каждого набора данных и набора данных. Среди недавних публикаций, использующих набор данных DAWN, средняя точность (mAP) нашего метода, равная 74,6%, является самым высоким достигнутым показателем, как подробно описано в Таблице 6.

Таблица 6. Сравнение наших результатов с некоторыми недавними публикациями, которые использовали набор данных DAWN.

Ссылка. Карта Арт. карта	Цель набора данных	Цель
[32][2]	32,75% ПАСБЕТ 32,75%	Ансамбльный подход для улучшения обнаружения объектов летательными аппаратами в неблагоприятных погодных условиях.
[33][3]	Туман 29,66% Дождь 41,21% ПАСБЕТ 61,43% Снег 43,01% Песок 24,13%	Модификация YOLO и использование нескольких наборов данных для обнаружения объектов в среде AV. Модификация YOLO и использование нескольких наборов данных для обнаружения объектов в среде AV.
[34][4]	39,19% DAWN	Архитектура для построения наборов данных для использования GAN и CycleGAN.
[35][5]	55,85% DAWN	Трансформатор обнаружения при слабом освещении (LDETR) для повышения эффективности обнаружения.
[36][6]	72,8% 72,8%	DAWN Улучшение YOLO с использованием метаматричных алгоритмов.
Наши 74,6% Наши 74,6%	ПАСБЕТ	Модификация YOLO и использование набора данных DAWN для классификации погоды и обнаружения объектов в AV-среде.

Для оценки классификации погоды предложенная модель получила точность 74,3% после 64 эпох, как показано на рисунке 11. Модель успешно классифицировала большинство сцен; однако в некоторых случаях модель не смогла классифицировать истинную погоду. Например, если мы посмотрим на Таблицу 7, в которой показаны экспериментальные результаты классификации погоды, на изображении номер 5 истинная погода представляла собой сильную песчаную бурю, тогда как модель классифицировала

Для оценки классификации погоды предложенная модель получила точность 74,3% после 64 эпох, как показано на рисунке 11. Модель успешно классифицировала большинство сцен; однако в некоторых случаях модель не смогла классифицировать истинную погоду. Для Например, если мы посмотрим на Таблицу 7, в которой показаны экспериментальные результаты классификации погоды, на изображении номер 5 настоящей погодой была сильная песчаная буря, тогда как модель классифицировала это как туманная погода. Этот случай является примером того, как яркость и освещение сцена может оказаться сложной задачей для моделей классификации погоды в неблагоприятную погоду.

Электроника 2024, 13, x НА ЭКСПЕРТИЗУ
Электроника 2024, 13, x НА ЭКСПЕРТИЗУ
Электроника 2024, 13, x НА ЭКСПЕРТИЗУ

15 из 21
15 из 21
15 из 21




Рисунок 11. Для классификации погоды наша модель набрала 74,3% после 64 эпох.
Рисунок 11. Для классификации погоды наша модель набрала 74,3% после 64 эпох.
Рисунок 11. Для классификации погоды наша модель набрала 74,3% после 64 эпох.
Рисунок 11. Для классификации погоды наша модель набрала 74,3% после 64 эпох.
Таблица 7. Результаты классификации.
Таблица 7. Результаты классификации.

Номер изображения	Изображение	Номер изображения	Изображение	Номер изображения	Изображение	Классифицировано	Классифицировано
1		1		2		Песчаная погода	Песчаная погода
2		2		2		Туманная погода	Туманная погода
3		3		3		Дождливая погода	Дождливая погода

Число	Изображение	Земля	Классифицировано
4		Снежная погода	Снежная погода
5		Песчаная погода	Туманная погода

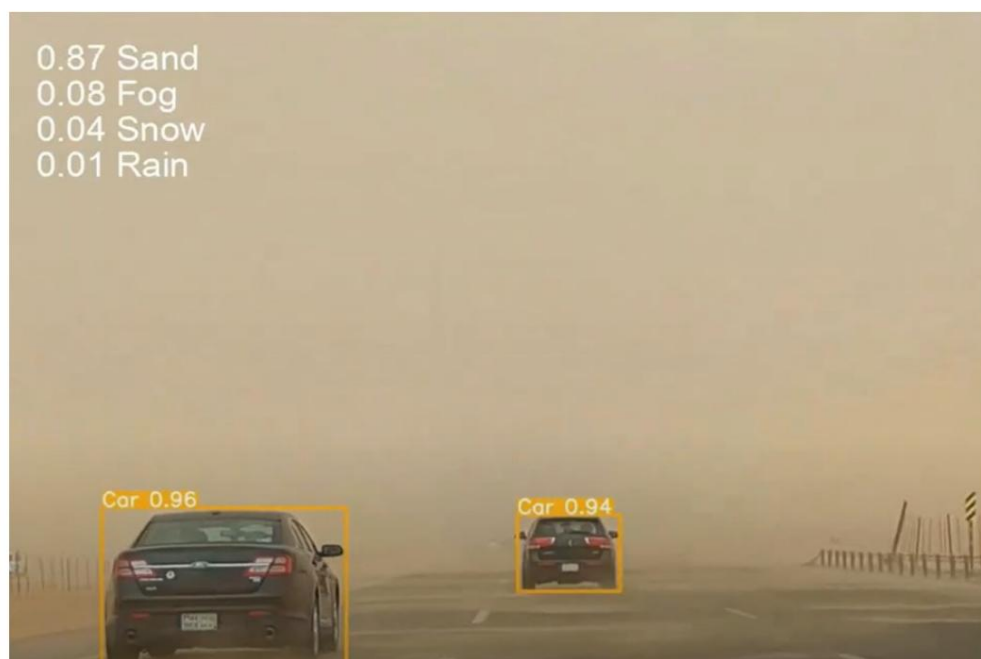
[illegible]

Рисунок 12. Модель успешно классифицировала песчаную погоду и обнаружила объекты на сцене.
Рисунок 13. Модель успешно классифицировала песчаную погоду и обнаружила объекты на сцене:



Рисунок 13. Модель успешно классифицировала туманную погоду и обнаружила объекты на сцене.



Рисунок 14. Модель успешно классифицировала дождливую погоду и обнаружила объекты на сцене.

Рисунок 14. Модель успешно классифицировала дождливую погоду и обнаружила объекты на сцене.

8. Обсуждение

Хотя предыдущий раздел демонстрирует потенциал нашего метода для обнаружения различных транспортных средств в неблагоприятных погодных условиях, в следующих пунктах мы обсудим ключевые идеи и наблюдения, возникшие в ходе работы:

- Если мы посмотрим на наш показатель F1 (рис. 10), класс «автомобиль» последовательно достигает самых высоких показателей F1 на разных уровнях достоверности, что указывает на то, что модель особенно хорошо справляется с точным обнаружением автомобилей. И наоборот, класс «грузовиков» обычно демонстрирует самые низкие оценки F1, что позволяет предположить, что модели может быть труднее различать грузовики или она может столкнуться с большим количеством ложноположительных/отрицательных результатов в этой категории. Кривая «все классы» представляет собой среднюю производительность по всем классам объектов, демонстрируя аналогичную тенденцию для отдельных классов, с пиковым показателем F1 около доверительного порога 0,6.
- Как показано в Таблице 6, предложенная нами работа достигла показателя mAP 74,6%. Этот результат превосходит результаты других публикаций по набору данных DAWN, включая ансамблевые методы [32], модификации YOLO [33], архитектуры на основе GAN [34], преобразователь LDETR [35] и YOLO, дополненный метаэвристическими алгоритмами [36]. • Примечательно, что набор данных DAWN представляет собой очень сложный набор данных, что подтверждается нашим собственным опытом и подчеркивается наблюдениями авторов в [33], которые заметили: «[мы] находим набор данных DAWN немного более сложным, чем другие». Эта проблема связана с тем, что некоторые изображения и объекты характеризуются чрезвычайно низкой видимостью, что является фактором, который может повлиять на итоговую оценку любой разработанной модели. • Область обнаружения объектов в неблагоприятную погоду по-прежнему требует более надежных наборов данных, которые обеспечивают достаточную изменчивость, чтобы охватить различные внешний вид объектов, условия освещения и окклюзии. Создание таких наборов данных требует много времени и средств. Недавно опубликованная статья Liu et al. [37] продемонстрировали подход на основе симулятора, который позволяет легко манипулировать условиями окружающей среды, размещением объектов и перспективой камеры. Использование сбора данных с помощью симулятора открывает двери для разнообразных и полных наборов данных без обширного сбора реальных данных. Этот подход может ускорить сбор данных за счет настройки и реализации различных сценариев неблагоприятных погодных условий, например, не дожидаясь сезонных изменений погоды. Более того, он обеспечивает масштабируемость данных, преодолевая географические ограничения сбора реальных данных.
- Хотя существующие недавние публикации и общедоступные наборы данных предлагают ценные ресурсы для обнаружения объектов в различных погодных условиях, существует очевидная потребность в дополнительных работах, включающих сценарии песчаной погоды. • Объединение изображений с LiDAR с использованием Fusion может стать многообещающим подходом для улучшения обнаружения объектов в автономных транспортных средствах. Недавние исследования, например, Dai et al. [38] и Лю и др. [39] продемонстрировали, что этот метод значительно улучшает обнаружение объектов в сложных условиях за счет использования дополнительных функций как LiDAR, так и камер. Камеры представляют собой экономичное и легкое решение, которое фиксирует насыщенные цвета и детали текстуры, помогая классифицировать и идентифицировать объекты. С другой стороны, LiDAR предлагает точные измерения расстояний и трехмерную пространственную информацию, что особенно полезно в условиях плохой видимости, где камеры могут испытывать трудности. Объединив данные обоих датчиков, можно значительно повысить точность и надежность систем обнаружения объектов. • Мы расширили наши эксперименты, чтобы проверить нашу модель, используя набор данных UAVDT [40]. Исходный набор данных UAVDT включает более 77 000 изображений, снятых в дневное, ночное время и в условиях тумана. Проведя эксперимент в течение 64 эпох, мы достигли следующих результатов: mAP 94,1%, полнота 90,8% и точность 97,0%. Мы считаем, что набор данных UAVDT требует дополнительной предварительной обработки, прежде чем его можно будет полностью использовать. Например, настройка временных рамок для захвата изображений может помочь разнообразить получаемые изображения.
- Синтетические данные могут использоваться для решения проблем и ограничений наборов данных в реальном времени. В недавней публикации [41] авторы предложили CrowdSim2, синтетический набор данных, для задач обнаружения объектов, в частности обнаружения людей и транспортных средств. Подобный метод может быть очень полезен для AV-сферы, предлагая контролируемую среду, в которой можно контролировать такие факторы, как погодные условия, плотность объектов и освещенность.

точно манипулируется, что позволяет тестировать модели обнаружения объектов в различных сценариях. Кроме того, его можно использовать для моделирования редких, но критических событий, таких как аварии или необычные препятствия, которые могут быть недостаточно представлены в реальных наборах данных.

9. Выводы

Классификация погоды и обнаружение объектов в суровых погодных условиях является важной и сложной задачей. В этой статье мы представили многоцелевую модель, которая объединяет классификацию погоды и обнаружение объектов и рассматривает их как единую проблему в области систем восприятия автономных транспортных средств. Наша модель состоит из двух основных блоков. Сначала блок качества проверяет качество изображения на основе оценки BRISQUE, и если изображение имеет оценку выше порогового значения, оно переходит к дальнейшему улучшению с помощью метода SRGAN. Во-вторых, блок классификации и обнаружения классифицирует четыре типа неблагоприятной погоды (снежная, дождливая, туманная и песчаная) и определяет шесть классов (автомобиль, велосипедист, пешеход, мотоцикл, автобус и грузовик). В ходе разработки мы использовали сложный набор данных DAWN в качестве источника изображений и использовали YOLO в качестве базовой структуры для классификации и обнаружения. Результаты экспериментов показывают, что наша модель достигла средней средней точности (mAP) 74,6% для обнаружения объектов с использованием архитектуры YOLO с архитектурой C3 в качестве магистрали и SiLU в качестве функции активации.

Кроме того, для классификации погоды на месте происшествия наша модель достигла точности 74,3%, что близко соответствует mAP. Тем не менее, в этой области все еще существуют некоторые проблемы, которые следует учитывать при разработке моделей обнаружения и классификации. Изменения характеристик сцены, таких как освещение и облачность, приводят к неправильной классификации правильной погоды.

10. Будущая работа

Неблагоприятные погодные условия по-прежнему остаются очень сложной задачей для AV-сред. Для достижения высочайшего уровня автоматизации сенсорам камеры необходима надежная система, способная безопасно перемещаться в различных погодных условиях и способная точно наблюдать за окружающей средой. В будущем мы расширим наш домен, включив в него дополнительные наборы данных, которые можно будет объединить с текущим набором данных DAWN. Это может привести к тому, что мы расширим наши классы обнаружения, включив в них более подробные и новые классы, которые мы наблюдаем в реальной среде вождения, например, светофоры, дети, домашние животные (например, собаки) и сотрудники правоохранительных органов (например, полицейские). Каждый из этих классов представляет собой неотъемлемые компоненты дорожной ситуации, и точное обнаружение и реагирование на их присутствие имеет важное значение для обеспечения безопасности и эффективности систем автономного вождения. Включив эти дополнительные классы в нашу систему обнаружения, мы стремимся улучшить общий mAP. Кроме того, мы стремимся улучшить перцептивные возможности автономных систем посредством перцепционного слияния, которое предполагает объединение информации от нескольких датчиков, таких как камеры, LiDAR, радары и ультразвуковые датчики, для создания комплексного и точного представления окружающей среды. Мы считаем, что, разработав такую надежную систему, мы сможем смягчить влияние неблагоприятных погодных условий на работу датчиков и повысить надежность и надежность общих систем AV-восприятия.

Вклад автора: Программное обеспечение NA; анализ данных, NA, AA и AB; курирование данных, NA; методология, NA; письменное – подготовка оригинального черновика, NA; написание — обзор и редактирование, AA и AB; супервизия, AA и AB; концептуализация, NA, AA и AB. Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: Данное исследование не получило внешнего финансирования.

Заявление о доступности данных: данные содержатся в статье.

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Рекомендации

1. Дж3016_202104; Таксономия и определения терминов, связанных с системами автоматизации вождения дорожных транспортных средств. Общество инженеров автомобильной промышленности (SAE): Уоррендейл, Пенсильвания, США, 2021 г.

2. Гиршик, Р.; Донахью, Дж.; Даррелл, Т.; Малик, Дж. Рич использует иерархии для точного обнаружения объектов и семантической сегментации. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Колумбус, Огайо, США, 23–28 июня 2014 г.; стр. 580–587.

3. Гиршик, Р. Фаст R-CNN. В материалах Международной конференции IEEE по компьютерному зрению, Севилья, Испания, 17–19 марта 2015 г.; стр. 1440–1448.

4. Рен, С.; Он, К.; Гиршик, Р.; Сан, Дж. Фастер R-CNN: На пути к обнаружению объектов в реальном времени с помощью сетей предложений регионов. Адв. Нейронная инф. Процесс. Сист. 2015, 28, 91–99. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)

5. Он, К.; Гкиоксари, Г.; Доллар, П.; Гиршик, Р. Маск R-CNN. В материалах Международной конференции IEEE по компьютерному зрению, Джайпур, Индия, 18–21 декабря 2017 г.; стр. 2961–2969.

6. Лин, Тайвань; Доллар, П.; Гиршик, Р.; Он, К.; Харихаран, Б.; Белонги, С. Функциональные пирамидальные сети для обнаружения объектов. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Пенанг, Малайзия, 5–8 ноября 2017 г.; стр. 2117–2125.

7. Редмон, Дж.; Диввала, С.; Гиршик, Р.; Фархади, А. Вы смотрите только один раз: унифицированное обнаружение объектов в реальном времени. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Бангалор, Индия, 20–21 мая 2016 г.; стр. 779–788.

8. Редмон, Дж.; Фархади, А. Йолов3: Постепенное улучшение. arXiv 2018, arXiv:1804.02767.

9. Ван, СУ; Бочковский А.; Ляо, HYM YOLOv7: Обучаемый набор подарков устанавливает новый уровень развития объектов реального времени детекторы. arXiv 2022, arXiv:2207.02696.

10. Лю, В.; Ангелов Д.; Эрхан, Д.; Сеги, К.; Рид, С.; Фу, СУ; Берг, АС Ssd: Мультибоксный детектор одиночного действия. В материалах Европейской конференции по компьютерному зрению, Амстердам, Нидерланды, 11–14 октября 2016 г.; Springer: Берлин/Гейдельберг, Германия, 2016 г.; стр. 21–37.

11. Дхананджая, ММ; Кумар, ВР; Йогамани, С. Классификация погоды и уровня освещенности для автономного вождения: набор данных, базовый уровень и активное обучение. В материалах Международной конференции по интеллектуальным транспортным системам (ITSC) IEEE 2021 г., Индианаполис, Индиана, США, 19–22 сентября 2021 г.; IEEE: Пискатауэй, Нью-Джерси, США, 2021 г.; стр. 2816–2821.

12. Кондапали М.; Кумар, КН; Вишну, К.; Мохан, К.К. К подходу к распознаванию переходных погодных условий для Автономные транспортные средства. IEEE Транс. Интел. Трансп. Сист. 2023, 25, 5201–5210.

13. Ибрагим, МР; Хаворт, Дж.; Ченг, Т. WeatherNet: Распознавание погодных и визуальных условий по изображениям улиц с использованием глубокого остаточного обучения. ISPRS Int. Дж. Гео-Инф. 2019, 8, 549. [\[CrossRef\]](#)

14. Ся, Дж.; Сюань, Д.; Тан, Л.; Син, Л. ResNet15: Распознавание погоды на дороге с помощью глубокой сверточной нейронной сети. Адв. Метеорол. 2020, 2020, 6972826. [\[CrossRef\]](#)

15. Он, К.; Чжан, Х.; Рен, С.; Сан, Дж. Глубокое остаточное обучение для распознавания изображений. В материалах конференции IEEE по Компьютерное зрение и распознавание образов, Бангалор, Индия, 20–21 мая 2016 г.; стр. 770–778.

16. Цао Ю.; Ли, К.; Пэн, Ю.; Ру, Х. MCS-YOLO: Многомасштабный метод обнаружения объектов для автономного вождения на дороге. признание. Доступ IEEE 2023, 11, 22342–22354.

17. Лю, З.; Лин, Ю.; Цао, Ю.; Хм.; Вэй, Ю.; Чжан, З.; Лин, С.; Го, Б. Трансформатор Суина: Трансформатор иерархического зрения с использованием смещенных окон. В материалах Международной конференции IEEE/CVF по компьютерному зрению, Монреаль, Британская Колумбия, Канада, 11–17 октября 2021 г.; стр. 10012–10022.

18. Пан Г.; Фу, Л.; Ю, Р.; Муресан, М.И. Распознавание состояния зимнего дорожного покрытия с использованием предварительно обученной глубокой сверточной нейронной сети. В материалах 97-го ежегодного собрания Совета по транспортным исследованиям, Вашингтон, округ Колумбия, США, 7–11 января 2018 г.; стр. 838–855.

19. Ван, Р.; Чжао, Х.; Сюй, З.; Дин, Ю.; Ли, Г.; Чжан, Ю.; Ли, Х. Обнаружение целей транспортного средства в режиме реального времени в сложных погодных условиях на основе YOLOv4. Передний. Нейробототехника 2023, 17, 34.

20. Ли, Х.; Ву Дж. Извлечение высокочастотных данных о движении транспортных средств из видео с беспилотных летательных аппаратов, снятого в различных погодных условиях. Remote Sens. 2022, 14, 5513. [\[CrossRef\]](#)

21. Лю, В.; Рен, Г.; Ю, Р.; Го, С.; Чжу, Дж.; Чжан Л. Адаптивное изображение YOLO для обнаружения объектов в неблагоприятных погодных условиях. В материалах конференции AAAI по искусственному интеллекту, Филадельфия, Пенсильвания, США, 27 февраля – 2 марта 2022 г.; Том 36, стр. 1792–1800.

22. Хуанг, Южная Каролина; Ле, ТН; Джоу, Д.В. DSNet: Совместное семантическое обучение для обнаружения объектов в суровых погодных условиях. IEEE Транс. Паттерн Анал. Мах. Интел. 2020, 43, 2623–2633.

23. Шарма, Т.; Дебак, Б.; Дюкло, Н.; Чехри, А.; Киндер, Б.; Фортъе, П. Обнаружение объектов и восприятие сцены на основе глубокого обучения в плохих погодных условиях. Электроника 2022, 11, 563. [\[CrossRef\]](#)

24. Юнг, Гонконг; Чой, Г.С. Улучшение yolov5: эффективное обнаружение объектов с помощью изображений дронов в различных условиях. Прил. наук. 2022, 12, 7255. [\[CrossRef\]](#)

25. АБДУЛГАНИ, АМА; ДАЛБЕРЕН, GGM Обнаружение движущихся объектов в видео с помощью алгоритмов YOLO и Faster R-CNN в различных условиях. Avrupa Bilim Ve Teknoloji Dergisi 2022, 33, 40–54. [\[Перекрестная ссылка\]](#)

26. Кенк, Массачусетс; Хассабалла, М. РАССВЕТ: Обнаружение транспортных средств в наборе данных о неблагоприятных погодных условиях. arXiv 2020, arXiv:2008.05402.

27. Миттал А.; Мурти, АК; Бовик А.С. Безреферентная оценка качества изображения в пространственной области. IEEE Транс. Процесс изображения. 2012, 21, 4695–4708. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)

28. Ледиг, К.; Тайс, Л.; Гусар, Ф.; Кабальеро, Дж.; Каннингем, А.; Акоста, А.; Эйткен, А.; Теджани, А.; Тотц, Дж.; Ван, З.; и другие. Фотореалистичное изображение сверхвысокого разрешения с использованием генеративно-состязательной сети. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Пенанг, Малайзия, 5–8 ноября 2017 г.; стр. 4681–4690.

29. Зоф Б.; Кубук, ЭД; Гиаси, Г.; Лин, Тайвань; Шленс, Дж.; Ле, К.В. Стратегии увеличения обучающих данных для обнаружения объектов. В материалах Computer Vision –ECCV 2020: 16-я Европейская конференция, Глазго, Великобритания, 23–28 августа 2020 г.; Шпрингер: Берлин/Гейдельберг, Германия, 2020 г.; стр. 566–583, часть XXVII 16.

30. Волк Г.; Мюллер, С.; Фон Бернут, А.; Хоспач, Д.; Брингманн, О. На пути к надежному обнаружению объектов на основе CNN посредством дополнения синтетическими вариациями дождя. В материалах конференции IEEE по интеллектуальным транспортным системам (ITSC) 2019 года; IEEE: Пискатауэй, Нью-Джерси, США, 2019 г.; стр. 285–292.

31. Парк, Х.; Йоу, Ю.; Со, Г.; Рука, Юн, С.; Квак, Н. С3: Концентрированная комплексная свертка и ее применение к семантическим сегментация. arXiv 2018, arXiv:1812.04920.

32. Валамбе, Р.; Марат, А.; Котеча, К.; Гинея, Г. Облегченная система ансамбля обнаружения объектов для автономных транспортных средств в сложные погодные условия. Вычислитель. Интел. Неврология. 2021, 2021, 5278820. [\[CrossRef\]](#) [\[PubMed\]](#)

33. Фарид А.; Хусейн, Ф.; Хан, К.; Шахзад, М.; Хан, У.; Махмуд, З. Быстрый и точный метод обнаружения транспортных средств в реальном времени. использование глубокого обучения для неограниченных сред. Прил. наук. 2023, 13, 3059. [\[CrossRef\]](#)

34. Мусат В.; Фурса, И.; Ньюман, П.; Куццолин, Ф.; Брэдли, А. Многопогодный город: сочетание неблагоприятных погодных условий для автономного вождения. В материалах Международной конференции IEEE/CVF по компьютерному зрению, Монреаль, Британская Колумбия, Канада, 11–17 октября 2021 г.; стр. 2906–2915.

35. Тивари, АК; Паттанаик, М.; Шарма, Г. Трансформатор DEtection TRansformer при слабом освещении (LDETR): обнаружение объектов при слабом освещении и неблагоприятных условиях. погодные условия. Мультимед. Инструменты Прил. 2024, 1–18. [\[Перекрестная ссылка\]](#)

36. Озджан И.; Алтун Ю.; Парлак, К. Улучшение эффективности обнаружения YOLO автономными транспортными средствами в неблагоприятных погодных условиях. Использование метаэвристических алгоритмов. Прил. наук. 2024, 14, 5841. [\[CrossRef\]](#)

37. Лю, С.; Чжан, Х.; Ци, Ю.; Ван, П.; Чжан, Ю.; Ву, К. AerialVn: Видео- и языковая навигация для БПЛА. В материалах Международной конференции IEEE/CVF по компьютерному зрению, Париж, Франция, 2–6 октября 2023 г.; стр. 15384–15394.

38. Дай, З.; Гуань, З.; Чен, К.; Сюй, Ю.; Сан, Ф. Улучшенное обнаружение объектов в автономных транспортных средствах с помощью LiDAR — датчика камеры. Слияние. Мировой Электр. Вех. J. 2024, 15, 297. [\[CrossRef\]](#)

39. Лю, Х.; Ву, К.; Ван, Х. Обнаружение объектов в реальном времени с использованием LiDAR и объединения камер для автономного вождения. наук. Отчет 2023, 13, 8056. [\[CrossRef\]](#) [\[PubMed\]](#)

40. Ду, Д.; Ци, Ю.; Ю, Х.; Ян, Ю.; Дуан, К.; Ли, Г.; Чжан, В.; Хуан, К.; Тиан, К. Эталон беспилотных летательных аппаратов: обнаружение и отслеживание объектов. В материалах Европейской конференции по компьютерному зрению (ECCV), Мюнхен, Германия, 8–14 сентября 2018 г.; стр. 370–386.

41. Фоснер, П.; Щесна, А.; Чампи, Л.; Мессина, Н.; Сайган, А.; Бизонь, Б.; Когель, М.; Гольба, Д.; Мациошек, Э.; Станишевский, М. CrowdSim2: открытый синтетический тест для детекторов объектов. arXiv 2023, arXiv:2304.05090.

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.



Статья

Влияние перегрузки канала связи на поток мощности и
Передача данных в киберфизических энергосистемах

Синь Юй Лю 1,2,3 , Янь Ли 1,2,3* Тяньц и Сюй 1,2,3

¹ Школа электротехники и информационных технологий, Университет Юньнань Миньцзу, Куньмин 650504, Китай; xylu7918@gmail.com (XL); xu.tianqi@ymu.edu.cn (ТХС)

² Ключевая лаборатория беспилотных автономных систем Юньнани, Куньмин 650504, Китай

³ Ключевая лаборатория киберфизической энергосистемы колледжей и университетов Юньнани, Куньмин 650504, Китай * Адрес для переписки: yan.li@ymu.edu.cn

Аннотация. Объем спроса на потоки в киберфизических энергосистемах (CPPS) колеблется неравномерно в связанных сетях и подвержен перегрузкам или перегрузкам из-за спроса на энергию со стороны потребителей или экстремальных стихийных бедствий. Поэтому, учитывая адекватность реальных сетей, каналы связи с избыточным информационным потоком не отключаются сразу, а имеют определенную степень избыточности. В данной статье предлагается динамическая итерационная модель каскадных отказов, основанная на распределении перегрузки информационного потока в сети связи и взаимосвязи потоков мощности в физической энергосистеме. Во-первых, представлена нелинейная модель нагрузки с учетом сети связи с перегрузкой и взвешенными ребрами, полностью учитывающая три состояния канала: нормальное, отказ и перегрузка. Затем взаимосвязь потоков заменяет ветвевые потоки в физической энергосети, а поток мощности на вышедших из строя линиях перераспределяется с использованием модели нагрузки с учетом того, что упрощает расчеты. В-третьих, под влиянием отношений связи строится комплексная модель, основанная на улучшенной теории перколяции, с стратегиями атаки, сформулированными для более точной оценки связанных сетей. Моделирование шинной системы IEEE-39 показывает, что учет нагрузки с учетом линий связи в небольших масштабах повышает надежность связанных сетей. Кроме того, преднамеренные атаки на каналы наносят более быстрый и обширный ущерб по сравнению с случайными атаками.



Цитирование: Лю, Х.; Ли, Ю. Сюй, Т. Импакт перегрузки канала связи на

Поток мощности и передача данных в

Киберфизические энергетические системы.

Электроника 2024, 13, 3065. <https://doi.org/10.3390/electronics13153065>.

Академический редактор: Христос Дж. Бурас

Поступила: 8 июля 2024 г.

Пересмотрено: 30 июля 2024 г.

Принято: 31 июля 2024 г.

Опубликовано: 2 августа 2024 г.



Копирайт: © 2024 авторов.

Лицензия MDPI, Базель, Швейцария

Эта статья находится в открытом доступе. Распространяется на условиях

лицензии Creative Commons

лицензия с указанием авторства (CC BY)

([https://creativecommons.org/licenses/by/](https://creativecommons.org/licenses/by/4.0/)

4.0/).

Ключевые слова: перегруженные ребра; поток информации; мощность потока; каскадные сбои; улучшенная теория перколяции; киберфизические энергетические системы

1. Введение

1.1. Предыстория

С развитием интеллектуальных сетей и энергетического Интернета энергетическая система становится связанной с информационной системой. Энергетическая система на физической стороне и система связи на информационной стороне постепенно превратились в киберфизическую энергетическую систему (КФЭС) [1]. Хотя объединенная система принесла множество преимуществ, она также увеличила риск каскадных сбоев в космосе. Уязвимости в двух системах из-за перекрывающихся элементов повысят риск распространения неправомерности, так что даже сбой одного ребра или узла может повлиять на всю сеть, что приводит к глобальному коллапсу [2,3]. Например, массовое отключение электроэнергии на западе США в 2003 г. оду, отключение электроэнергии на Украине в 2015 г. оду и отключение электроэнергии 815 в Бразилии в 2023 г. оду [4,5] были вызваны выходом из строя определенных границ информационной сети. Эти сбои распространились на энергосистему через функциональную связь, что в конечном итоге привело к одновременному параличу обеих систем.

1.2. Сопутствующие работы

Анализ прошлых случаев показывает, что когда с истема связи выходит из строя или подвергается атаке, пакеты данных могут быть потеряны или изменены, что препятствует управлению с обратной связью. Из-за киберфизической связи сбой с определенной вероятностью распространяется и затронет иловые узлы физической сети. Затем сбой продолжает распространяться по физической сети, что в конечном итоге приводит к серьезному повреждению с истемы [6–8]. Поэтому моделирование физической энергосистемы, сети связи и ее соединительных соединений имеет важное значение для понимания процесса распространения каскадных

В [9] была предложена модель связи «один к одному» между иловыми и коммуникационными узлами, анализирующая устойчивость с истемы каскадных отказов после удаления небольшой части узлов на основе ее топологической модели. В [10] авторы исследовали устойчивость двухслойной безмасштабной сети связи, основанной на теории перколяции.

На основе [10], ссылка [11] считала взаимодействия между узлами на разных уровнях гетерогенными, изучая тип каскадной динамики в двухуровневых сетях, которые демонстрируют как взаимозависимость, так и связность. На основе [9,10] Chen et al. [12] разделили узлы физической энергосистемы на узлы генератора и нагрузки, предложив новый интерактивный механизм каскадных отказов. В [13] эксплуатационные характеристики и топологическая структура сети передачи были интегрированы для создания модели каскадных отказов для случайных неисправностей в линиях передачи при различных стратегиях связи с целью получения оптимальной устойчивой связанной сети. Однако модели связи, созданные в этих исследованиях, сосредоточены исключительно на топологических структурах, игнорируя эксплуатационные характеристики обеих сторон связанных сетей. В [14,15] рассматривалась оптимизация потока мощности в физической энергосети и сравнивались результаты устойчивости при различных стратегиях и топологиях информационной сети, но не рассматривались эксплуатационные характеристики информационной сети. В [16] изучалось динамическое распространение каскадных отказов между энергосистемой и сетью связи, учитывая характеристики потока мощности и потока данных в двух различных системах, но влияние перегрузки данных в сети связи на связанную сеть не рассматривалось.

В [17] были изучены характеристики восстановления различных сил связи и топологий сети на основе каскадной модели, связанной с нагрузкой. Хотя в данной модели учитывалось состояние перегрузки узлов, перераспределение дополнительной нагрузки не осуществлялось. На основе [16,17] Ding et al. [18] предложили улучшенную модель каскадных отказов. Эта модель учитывает состояние перегрузки и процесс восстановления киберузлов, а также оптимизацию потока мощности на физическом уровне и перераспределение потока информации при распространении неисправности. Основываясь на этом, Wang et al. [19] использовали модель потока мощности переменного тока для характеристик эксплуатационных характеристик энергосистемы, повышая точность модели энергосистемы. Одновременно была построена взвешенная сеть связи с центрами управления и применена модель перераспределения потоков. В [20] авторы предложили два типа моделей сильной и слабой зависимости и проанализировали изменения устойчивости сети связи с использованием схем балансировки нагрузки с учетом перегрузок при начальных случайных неисправностях на уровне мощности. Однако потоки данных на уровне связи не рассматривались. Авторы [21,22] рассматривали отказы узлов связи и создали улучшенную модель каскадных отказов, основанную на распределении нагрузки на физическом уровне. В [23] предложенная авторами модель рассматривала практические различия между сетью связи и энергетической сетью с точки зрения сетевой структуры, физического функционирования и динамического поведения, уделяя особое внимание анализу неисправностей, возникающих на стороне электросети. Из этих исследований видно, что большинство ученых уделяют меньше внимания задержкам передачи, вызванным перегрузкой трафика в сетях связи, и созданию связанных моделей, учитывающих эксплуатационные характеристики обеих сетей.

1.3. Мотивация

Фактически, многие соединенные ребра часто обладают избыточной пропускной способностью. Например, на рисунке 1a показана сеть связи с пятью узлами. Матрица A представляет собой матрицу потребности в передаче информационного потока, где элементы F_{ij} обозначают информационный поток

с прос, который необходимо передать от источника к месту назначения. Каждому каналу e_{ij} соответствует атрибут качества q_{ij} [24,25], где рабочий уровень канала e_{ij} определяется как отношение пропускной способности канала к нагрузке канала. Предполагая, что порог отказов равен ρ , если исходными неисправностями в сети связи являются звенья с $\rho < 0,5$, эти звенья будут удалены из исходной сети (например, удалить 1-2, 2-3). В этот момент передача информационного потока по каналу связи не страдает (каналы 1-4 и 2-1 все еще существуют), но каналы 1-4 и 2-1 находятся в перегруженном состоянии. Потребность в информационном потоке по исходному каналу 1-2 будет перераспределена на канал 1-4-2. Хотя это не сразу и перегруженные каналы не откажут, качество передачи будет продолжаться и снижаться. При увеличении порога до $\rho = 0,7$ эффективность работы канала 1-4 падает ниже критического порога, в результате чего состояние ребра меняется с перегруженным на неисправное, и оно удаляется из исходной сети. На этом этапе затрагиваются 25 требований передачи информационного потока (выделены красным на рисунке).

При дальнейшем увеличении порога до $\rho = 0,9$ связи с $q_{ij} < 0,9$ удаляются. Как показано на рисунке 1d, только одиннадцать единиц трафика могут быть эффективно переданы в центр управления. Видно, что в процессе изменения порога и удаления звеньев, если не учитывать перегруженное состояние и потребность в потоке передачи звеньев, сеть преждевременно выйдет из строя, что приведет к значительным потерям в энергосистеме.




Рисунок 1. Диаграмма отказа канала связи в зависимости от потребности в потоке информации. (а) Сеть связи G размера $n = 5$, где четвертый узел является центром управления, а остальные являются обычными узлами передачи. Качество q_{ij} каждой строки e_{ij} отмечено рядом со ссылкой. Матрица F представляет потребность в передаче информационного потока. (б) Предположим, что исходными неисправностями в сети связи являются каналы с $\rho < 0,5$. (в) Увеличение порога до $\rho = 0,7$, удаляя при этом ссылки с $q_{ij} < 0,7$. (д) При дальнейшем увеличении порога до $\rho = 0,9$ каналы с $q_{ij} < 0,9$ удаляются и только одиннадцать единиц требуемого трафика могут быть эффективно переданы в центр управления.

Обычно, когда в энергосистеме происходит бой N-1, сходимостью потока необходимо пересчитывать для каждого сценария. Если поток сходится, то необходимо определить, выходит ли поток на каждой линии за свои пределы; в этом случае пораженную линию следует обрезать. Если он не сходится, обычно применяются сброс нагрузки или регулировка выходной мощности генератора для балансировки потоков мощности. Перечисление всех сценариев может быть сложным и трудным. Поэтому в данной статье предлагается применить межлинейный поток между потоками [26] к модели «нагрузка-мощность» энергосистемы, используя ее в качестве силовой нагрузки на линии. Этот подход эффективно отражает и количественно определяет роль линий в передаче мощности от генераторов к нагрузкам, а также учитывает влияние максимальной доступной мощности передачи между генераторами и нагрузками на критические линии. Этот физический фон более тесно связан с

реальную работу энергосистем и лучше отражает их эксплуатационные характеристики. При моделировании процесса передачи информации поток решает значение имеет отличие его от энергосети. Каналы информации уровня не будут отключаться из-за перегрузки информации потока, но вызовут перегрузку, если поток будет чрезмерным. Необходимо учитывать перегруженное состояние при перераспределении информации потока от неработающих каналов связи с одним для разработки более реалистичной модели потоков электроэнергетической сети. Таким образом, в данной статье, рассматривая прерывания связи в системе связи, предлагается модель каскадного отказа нагрузки и мощности, основанная на усовершенствованной теории перколяции, объединяющая перегрузку информации потока и эксплуатационные характеристики энергосистемы. Эта модель анализирует влияние перегруженных каналов

1.4. Взносы

Вклад этой статьи резюмируется следующим образом:

- Учитывая состояние перегрузки каналов связи, устанавливается модель динамического распределения передачи для потока информации в трех состояниях канала – нормальном, перегрузке и бое. Предложены метрики относительной топологии системы связи и эксплуатационных характеристик для оценки уязвимости системы в случае бое.
- С учетом особенностей формирования топологии реальных сетей электроэнергетической связи предлагается усовершенствованная теория перколяции. Узлы связи, которые изначально находятся за пределами крупнейшего подключенного компонента, но имеют каналы связи с центром управления, считаются эффективными узлами. Силовые узлы, которые теряют связь с сетью связи, но остаются аморфными, также считаются эффективными узлами.
- Учитывая физические характеристики связанных сетей, индикатор межлинейного потока используется для измерения электрических характеристик линейных потоков мощности. Для передачи нагрузки вышедших из строя линий предложена модель распределения нагрузки и мощности, основанная на взаимосвязи потоков.

Остаточная часть теста организована следующим образом. В разделе 2 мы построим модель односторонней зависимости CPPS и дадим подробное описание процесса распространения неисправности в простом трансформаторе с учетом случайной перегрузки линии связи в рамках связанной модели. В разделе 3 мы предлагаем две метрики оценки устойчивости системы для измерения результатов каскадных бое. В разделе 4 проводится численное моделирование для анализа каскадного отказа и представлены соответствующие обсуждения. Раздел 5 завершает статью.

2. Методы

2.1. Моделирование связанных сетей электропитания и связи на основе односторонней

зависимости CPPS включает моделирование информационной сети, энергосети и уровня связи. Информационная сеть включает уровень доступа, магистральный уровень и базовый уровень.

Взаимозависимые ребра между узлами питания и информационными узлами образуют сеть связи [27]. В соединительной сети электропитания обеспечивает поддержку электропитания сети связи, а сеть связи обеспечивает поддержку ЗС для сети электропитания. Однако поскольку узлы связи широко оснащены резервными источниками питания, выход из строя связанных узлов питания не приводит к выходу из строя узлов связи из-за отключения электроэнергии. Нормальная работа силовых узлов зависит от мониторинга и управления узлами связи. Выход из строя каналов связи приведет к тому, что центр управления не сможет временно получать информацию о неисправностях энергосистемы, что приведет к невозможности оперативного реагирования на сбои в электроснабжении и расширению масштабов воздействия неисправностей. Поэтому в данной статье в первую очередь рассматривается модель зависимости электросети от информационной сети. Ссылаясь на блок-схему на рисунке 2, процесс моделирования подробно описан следующим образом:

- (1) Физическая энергосистема абстрагируется как граф $G_p(V_p, E_p)$, состоящий из энергетических узлов V_p и линий передачи E_p . Набор V_p включает физическое оборудование в электросети, такое как электростанции, подстанции и нагрузки.

- (2) Разделить энергосистему на регионы [28].

а. Разделение населенных пунктов применяется для разделения регионов электросетей. В электросети, чем ближе расстояние между двумя машинами, тем меньше реактивное сопротивление линии и тем больше его обратное значение (т.е. более высокий вес), что указывает на более высокую близость между парой узлов. Таким образом, такие узлы с большей вероятностью будут разделены на один и тот же регион. Обратная величина реактивного сопротивления линии используется в качестве весов ненулевых элементов матрицы смежности электросети E . б. Используя метод Фаста Ньюмана, модифицированная матрица A_E , полученная на вышеуказанных этапах, заменяется A_E одной матрицей E для расчета модульности Q для первоначального разделения энергосети. Процесс разделения должен удовлетворять следующим условиям: каждый регион должен содержать хотя бы один генератор и одну нагрузку; количество регионов должно быть меньше минимального количества генераторов и нагрузок; и субрегионы должны достигать баланса сил. в. Для достижения баланса мощности внутри регионов потоки мощности системы на линиях используются в качестве весовых значений на основе алгоритма Prim. Эти значения весов используются для определения путей потока от генераторов к нагрузкам. Затем регионы объединяются с соответствующими этими путями и объединяются с первоначальными результатами разделения для формирования окончательных зон.

- (3) Определяется количество узлов для каждого уровня уровня дотупа, магистральный уровень и базовый уровень. Узлы уровня дотупа представляют собой узлы базовой информации, количество узлов связи которых равно количеству узлов питания; узлы магистрального уровня — это узлы оборудования маршрутизации, также расматриваемые как узлы управления с количеством узлов, равным количеству разделов электросети; а узлы базового уровня представляют собой два узла управления, представляющие основную и резервную диспетчеризацию.

- (4) Моделирование информационной сети: а. Соединение

между электросетью и уровнем дотупа: согласно абстрактной схеме электросети G_p , узлы уровня дотупа соединены соответствующим образом «один к одному», чтобы сделать топологическую диаграмму уровня дотупа согласно топологической схеме. б. Связь между уровнем дотупа и магистральным уровнем: узлы высшего уровня в каждой области уровня дотупа и узлы-генераторы подключены к соответствующим узлам магистрального уровня. в. Узлы магистрального уровня соединены внутри с соответствующими соединениями.

взаимосвязь разделов электросети.

- д. Связь между уровнем дотупа и уровнем ядра: вычислить долю q_i выхода генератора G_i к общему выходу системы и соединить ее с основными и резервными вызовами с вероятностью q_i .

е. Все узлы маршрутизации подключены к основному и резервному узлам центра планирования. ф. Подключены основной и резервный диспетчерские центры.

- (5) Абстрагируем информационную сеть, чтобы сформировать G_c .

- (6) Соедините узлы уровня дотупа с узлами питания, чтобы сформировать однонаправленные зависимые ребра.




Рисунок 2. Блок-схема моделирования киберфизической энергосистемы.

Таким образом, связанные сети показаны на рисунке 3.




Рисунок 3. Схематология электросети в зависимости от информационной сети.

2.2. Модель каскадного отказа на основе теории перколяции с учетом перегрузок каналов связи

2.2.1. Нелинейная модель потока для сетей

Модель информационного потока сети связи использует нелинейную модель мощности нагрузки, которая учитывает состояние перегрузки [29]. В сложных сетях более высокий уровень узла указывает на большее количество соединений с другими узлами. Следовательно, значения степени конечных точек используются для расчета информационного потока каждого канала уровня дуги. Чем выше значение степени ссылки, тем больший поток информации через нее. Коэффициент потока информации по каналу используется в качестве веса канала, а коэффициент перегрузки δ описывает способности ребра обрабатывать дополнительный поток информации следующим образом:

$$C_{c,ij} = L_{c,ij} + \beta \sum_{\alpha} c_{\alpha,ij} \tag{1}$$

$$C_{c,ij}^{\text{Макс}} = \delta C_{c,ij} \quad (2)$$

$$W_{c,ij} = \begin{matrix} \frac{L_{c,ij}}{C_{c,ij}} & e_{ij} & EC \\ 0 & e_{ij} & / EC \end{matrix} \quad (3)$$

где

$$L_{c,ij} = w_{ij} = k_{ij} \theta \quad (4)$$

где $L_{c,ij}$ представляет собой объем информации, передаваемой по каналу связи, а k_i и k_j обозначают степень узлов i и j соответственно. θ — параметр, регулирующий поток информации. $C_{c,ij}$ — пропускная способность линии, $C_{c,ij}^{\text{Макс}}$ представляет собой максимальный поток, который может выдержать линия, а $W_{c,ij}$ — это вес ребра e_{ij} . α и β — коэффициенты мощности. Когда $\alpha = 1$, модель линейна.

2.2.2. Усовершенствованная теория

Перколяция. Традиционная теория перколяции [30] широко используется для описания структуры, функций и устойчивости сетевых систем. Модели перколяции моделируют сценарии отказа каналов путем постепенного удаления каналов из сети. Поскольку ссылки постепенно удаляются, уменьшение размера наибольшего связанного подграфа можно использовать для измерения последствий сбоя ссылок. Таким образом, теория перколяции применима для моделирования каскадных сбоев в киберфизических энергосистемах. Однако традиционная теория перколяции при определении подмножества рабочих узлов учитывает только самое большое подключенное подмножество в одноуровневой сети, не рассматривая другие сценарии. Непосредственное применение его для моделирования каскадных отказов в киберфизических энергосистемах затрудняет точное моделирование процесса отказа. Учитывая характеристики передачи информации о потоке информации в сети, где базовый уровень и магистральный уровень не соответствуют напрямую уровню дотупа, а состояние канала учитывает ситуацию перегрузки, необходимо усовершенствовать классическую модель теории перколяции. Модель отказа киберфизической энергосистемы, установленная этой статьей, выглядит следующим образом:

- Система связи. Для каналов уровня дотупа ребра с весами,

превышающими коэффициент перегрузки, считаются отказавшими. Для информационных узлов на уровне дотупа узлы, которые не могут установить путь к узлам управления, считаются вышедшими из строя.

- Система питания. Узел силовой нагрузки должен быть подключен к одному генераторному узлу; в противном случае он считается неудачным. Аналогично, узел генератора должен быть подключен к одному узлу силовой нагрузки; в противном случае он считается неудачным. Узлы, функционирующие как генераторы, так и нагрузки, считаются автономными узлами.
- Взаимодействие. Силовые узлы в сочетании с вышедшими из строя узлами связи также выйдут из строя. Кроме того, узлы питания, связанные с узлами связи, выходящими из задержек передачи, выйдут из строя с определенной вероятностью P_{di} .

2.2.3. Модель нагрузки и мощности энергосети на основе взаимосвязи потоков

В предыдущих исследованиях принцип распространения по кратчайшему пути обычно использовался для исследования передачи энергии между шинами в энергосети. Однако в действительности поток мощности в электрической сети не следует только по пути с наименьшим сопротивлением, а распространяется по всем возможным путям, придерживаясь закона Кирхгофа.

Чтобы точно отразить роль каждой линии передачи в распространении мощности и различное влияние различных пар генератор-нагрузка на каждую линию, учтите, что в данной энергосети каждая линия передачи несет различную долю передаваемой мощности $P(m, n)$ от генератора m к нагрузке n . Следовательно, каждая линия играет различную роль и имеет различные уровни значимости в мощности передачи $P(m, n)$. Поскольку пути передачи электроэнергии для пар генератор-нагрузка пересекают каждую линию, различаются значимость линии в целом

с есть оценивается количественно с использованием индекса взаимовязи потоков [26]. Этот индекс рассчитывается путем расчета пар генератор-нагрузка, используя их линию. Формула расчета следующая:

$$FB_{ij} = \frac{\min(S_m, S_n)}{m^2 G n^2 L} \frac{P_{ij,m} P_{ij,n} P_n}{P_{ij} P_{Ln} P_m} \quad (5)$$

где G — сбалансированная генерация, а L — сбалансированная потребителей. $\min(S_m, S_n)$ — это вес между потоками одной линии, который зависит от минимального значения между фактической выходной мощностью генератора m и фактической нагрузкой n , отражая максимальную доступную мощность передачи между m и n . $P_{ij,m}$ — часть потока мощности по линии ij , исходящая от генератора m . $P_{ij,n}$ — часть потока мощности по линии ij , направленная на нагрузку n . P_n — поток мощности узла n . P_{ij} — активная мощность по линии ij . P_{Ln} — активная нагрузка в узле n . P_m — активная нагрузка в узле m . Следовательно, силовая нагрузка $L_p(ij)$ на ребре ij может быть рассчитана как

$$L_p(ij) = FB_{ij} \quad (6)$$

Принимая во внимание способность линий выдерживать силовые нагрузки, мы используем модель «нагрузка-мощность», предложенную Моттером и Лаем [31]. Согласно этой модели, пропускная способность линии пропорциональна ее начальной силовой нагрузке следующим образом:

$$C_p(ij) = (1 + \gamma) L_p(ij) \quad (7)$$

где γ — параметр допуска.

2.2.4. Процесс каскадного отказа.

Информационная сеть способна контролировать энергетические узлы. Следовательно, неисправности, возникающие в информационной сети, могут распространиться на взаимосвязанную энергосеть. В этом разделе подробно описан динамический процесс каскадных сбоев, вызванных определенными неисправными каналами связи.

В зависимости от величины передаваемого информационного потока в сети связи рабочие состояния линий связи подразделяются на три типа: нормальное, перегруженное и отказное. Для анализа каскадных сбоев между связанными сетями некоторые каналы в сети связи случайным образом удаляются как первоначальные сбои. Ссылка на блок-схему на рисунке 4, подробный динамический процесс каскадных сбоев, вызванных конкретными поврежденными ссылками, описывается следующим образом:

- Шаг 1: Набор вышедших из строя каналов в сети связи уровня дуга из-за случайных сбоев или атак обозначается как e_{ij} . Информационный поток по этим вышедшим из строя каналам будет нести ребра, соединенные с узлами вышедших из строя каналов.
- Шаг 2: Процесс распределения потока информации по отказавшим ветвям. В данной статье используется принцип локального перераспределения информационного потока, формула расчета которого представлена следующим образом.

$$L_{c,ia} = L_{c,ij} \frac{L_{c,ia}}{\Omega L_{c,im} + \sum_{n \in \Omega} L_{c,jn}} \quad (8)$$

где $L_{c,ij}$ — исходный информационный поток на ветви ij , $L_{c,ia}$ — начальный информационный поток на ветви ia , Ω — множество оседлых узлов узла i , а $\sum$ — множество оседлых узлов узла j .

- Шаг 3: Процесс определения состояния перегрузки и сбоя выводится следующим образом.

$$\begin{aligned} W_{c,im} &> \delta && \text{неудача} \\ 1 < W_{c,im} < \delta \text{ и } rand > p_{im} && \text{перегрузка} \\ 1 < W_{c,im} < \delta \text{ и } rand < p_{im} && \text{не работают} \\ W_{c,im} &= 1 && \text{нормальный} \end{aligned} \quad (9)$$

где $rand \in (0, 1)$.

Поскольку каждая ветвь имеет разные возможности обработки дополнительного потока информации, для характеристики этого состояния вводится коэффициент распределения ω .

$$p_{ia} = \frac{W_{c,ia} - 1}{\delta - 1} \omega \quad (10)$$

- Шаг 4: Процесс распределения информационного потока по перегруженным ветвям:

$$a_k = (L_{c,ia} - C_{c,ia}) T_{ak} \quad (11)$$

$$T_{ak} = \frac{C_{c,ak} - L_{c,ak}}{e - \Omega(C_{c,ie} - L_{c,ie}) + f - \Omega(C_{c,af} - L_{c,af})} \quad (12)$$

где a_k — стратегия распределения перегруженной ветви, Ω — множество осевых узлов узла i с ветвями в нормальном состоянии, Ω — множество осевых узлов узла a с ветвями в нормальном состоянии.

- Шаг 5: Определите, есть ли новые неудачные ветки. Если новые неудачные ветки

обнаружены, перейдите к шагу 2; в противном случае перейдите к шагу 6.

- Шаг 6: Подсчитайте количество вышедших из строя и перегруженных каналов с вью в сети с вью. Обновите эффективный набор каналов с вью и рассчитайте приращения задержки и передачи для каждого узла с вью. Оценить условия отказа узлов с вью, удалить узлы, которые не могут сформировать путь к центру управления и обновить набор эффективных узлов с вью.

- Шаг 7: Анализ зависимости управления. Из-за взаимно однозначной связи между узлами с вью уровня дотупа и узлами питания вышедшие из строя узлы с вью, определенные на этапе 6, приведут к выходу из строя соответствующих узлов питания через зависимые ребра. Узлы выбирают ся на основе вероятности задержки каждого узла с вью.

Если информация этих узлов не будет своевременно передана в центр управления с соответствующими им сивовые узлы с читаются вышедшими из строя. Отметьте узлы питания, вышедшие из строя на этом этапе.

- Шаг 8. Физический сбой. Сначала удалите

вышедшие из строя узлы электросети. Далее, исходя из условий отказа узлов энергосистемы, проверяют, есть ли среди оставшихся узлов дополнительные вышедшие из строя при необходимости удалять их. Пересчитать сивовую нагрузку на линии; если перераспределенная нагрузка превышает пропускную способность какой-либо линии, пометьте эту линию как неисправную. Повторяйте этот процесс до тех пор, пока в электросети не останутся исправных узлов.

- Шаг 9: Результат: моделирование одиночного отказа завершается.

Выведите данные для обоих энергетических сетей с вью.




Рисунок 4. Блок-схема процесса каскадного отказа в киберфизических энергосистемах.

3. Метрики оценки устойчивости системы к каскадным сбоям. В CPPS

Любое неисправное звено потенциально может распространяться через связи и перерастать в каскадные сбои. Чтобы проанализировать влияние первоначальных сбоев на систему, мы определяем метрики оценки для обеих связанных сетей на основе целостности топологии сети и эксплуатационных характеристик.

3.1. Метрики коммуникационной сети

В сети связи мы используем скорректированные показатели выживаемости узлов/каналов для оценки целостности топологии сети связи. Учитывая, что в перегруженном состоянии каналы связи имеют поток информации, превышающий их пропускную способность, в отличие от нормальных узлов, эти каналы работают неэффективно и имеют определенную вероятность перехода в неисправное состояние. Поэтому, чтобы отличить нормальные и перегруженные каналы связи и более точно представить влияние перегруженного состояния на систему, для оценки каналов связи после настройки используется относительный размер наибольшего связанного компонента G_c [29]. Уровень выживаемости узлов/каналов после отказа используется для оценки топологической целостности, как подробно описано ниже:

$$G_c = \frac{h \in \Psi_{sh}}{N_k} \quad (13)$$

где N_s — количество узлов на уровне доступа сети связи. Ψ обозначает множество исправных узлов. Когда информационные каналы находятся в нормальном состоянии, $sh = 1$.

Однако, когда информационные каналы находятся в условиях перегрузки, sh рассчитывается следующим образом:

$$sh = \frac{\delta Ch \cdot Lh}{\delta Ch \cdot Ch} \quad (14)$$

Тогда скорректированная выживаемость узла/канала равна

$$ФК = \frac{1}{2} * \left(\frac{B_c^I}{B_K} + \Gamma_c \right) \quad (15)$$

Из-за отключения информационных каналов путь от узлов уровня дотупа сети до центра управления может измениться, что приведет к задержкам в сети. В данной статье задержка передачи данных упрощена и рассчитана следующим образом [32]: Передача данных в сети с выключением осуществляется по принципу кратчайшего пути, и каждый раз, когда они проходят через узел данных, задержка увеличивается на одну единицу времени t . Единица времени задержки отражает задержку, вызванную передачей и обработкой данных от узла источника к узлу назначения в сети с выключением, включая прохождение через каждый информационный узел и путь с выключением к следующему информационному узлу.

Следовательно, приращение задержки передачи T , вызванное сетью с выключением, рассчитывается следующим образом:

$$T = \sum_{k \in L_c} T_{\pi c}^I + \sum_{k \in L_c} T_{\pi c} \quad (16)$$

где $T_{\pi c}^I$ и $T_{\pi c}$ — задержка пути передачи одних и тех же пар источник-назначение после и до сбоя кадрирования. L_c обозначает набор кратчайших путей передачи для всех пар источник-назначение в сети с выключением.

3.2. Метрики электросети

В физической энергосети мы используем влияние отказа F_r для оценки влияния каждого отказа [12], выражаемое как

$$Фп = \frac{1}{2} T \left(\frac{V_{\pi}^I}{V_{\pi}} \right) + \frac{\varepsilon_{\pi}^I}{\varepsilon_{\pi}} \quad (17)$$

где V_{π}^I и ε_{π}^I соответственно — количество вышедших из строя узлов и звеньев электросети. V_{π} и ε_{π} соответственно представляют собой общее количество узлов и звеньев в физической энергосети.

4. Тематическое исследование и обсуждение

В этом разделе на примере системы с шиной IEEE 39 топология электросети показана на рисунке 5, а их одна топология разделена на четыре региона на основе принципов зонирования. Соответственно, сеть энергосвязи, созданная в соответствии с вышеупомянутыми правилами, изображена на рисунке 6. В этой сети уровень дотупа состоит из 39 узлов с выключением, каждый из которых соответствует одному из 39 силовых узлов, которые используются для загрузки информации о нештатных ситуациях и выдачи инструкций по отправке.

Максимальный уровень включает в себя четыре узла управления, каждый из которых соответствует своей области уровня дотупа. Диспетчерский центр оборудован двумя узлами управления.




Рисунок 5. Схема разделов с системы шины IEEE 39.





Рисунок 6. Схематопологии и информационной сети, созданной 39-шинной с системой IEEE.

4.1. Влияние коэффициента перегрузки


Чтобы изучить влияние коэффициента перегрузки на надежность сети, количество начальных неисправностей каналов варьировалось, при этом каждый набор неисправных каналов генерировался случайным образом. Моделирование запускалось независимо 50 раз, и среднее значение принималось за метрику сети связи. Для наглядности представления на диаграммах использовались текстовые описания при полном отказе системы связи, а для текстового пояснения выбирался набор данных с наибольшим количеством вышедших из строя каналов, вызвавших полный отказ системы связи. Согласно рисунку 7а, по мере увеличения количества их одних неисправных каналов выживаемость узлов/каналов в сети связи постепенно снижается. Если не учитывать перегрузочную способность каналов, выживаемость узлов/каналов в сети будет самой низкой. Когда коэффициент перегрузки равен 1,2, выживаемость узлов/каналов в сети связи значительно улучшается. Однако можно заметить, что при коэффициентах перегрузки 1,3 и 1,5 выживаемость узлов/каналов существенно не улучшается.

Рисунок 7б показывает, что CPPS при различных коэффициентах перегрузки демонстрирует перекрывающийся переход первого рода с аналогичной общей тенденцией. По мере увеличения количества вышедших из строя линий топология информационного уровня нарушается, а некоторые узлы теряют пути передачи данных. Изменение пути передачи увеличивает задержку системы. При коэффициенте перегрузки 1,5 количество вышедших из строя звеньев, которое может выдержать сеть связи до полного разрушения, является наибольшим. Как видно на рисунке 7б и в таблице 1, существует пороговое значение для начального числа вышедших из строя каналов, вблизи которого эффект каскадного отказа распространяется на все каналы связи, не оставляя пути передачи между узлами связи и центром управления. В этот момент система связи полностью выходит из строя, что делает невозможным управление электросетью. В таблице 1 показаны конкретные пороговые значения для различных коэффициентов перегрузки.

Поэтому, учитывая затраты на строительство сети, коэффициент перегрузки установлен равным 1,3 согласно рисунку 7 и таблице 1.



(a)



(b)

Рисунок 7. Устойчивость сети связи и приращение задержки связи при различных коэффициентах перегрузки. (а, б) соответственно показывают связь между устойчивостью сети связи и задержкой системы с увеличением числа отказов линии связи при различных коэффициентах перегрузки, при этом остальные параметры остаются постоянными.

Таблиц а 1. Порог и работы с и с т е м ы при различных коэффициентах перегрузки.


Коэффициент перегрузки	Порог начальных неудачных линий	Пороговый процент %
1,0	9	19.56
1,1	9	19.56
1,2	10	21.74
1,3	11	23.91
1,5	12	26.09

4.2. Влияние неудачных ссылок


В этом разделе мы проанализируем влияние на передачу данных в пределах мощности и сети связи путем последовательного удаления каждого из звена сети связи.

Как показано на рисунке 8, большинство неисправных каналов связи имеют различные последствия топологическую целостность и эксплуатационные характеристики СЗПС. Ссылки, которые вызывают значительные сбои в работе системы определяются как критические звенья. В условиях неисправности N-1 все перечислены возможные сценарии системных атак.

Как показано на рисунке 8, можно заметить, что сбой одного канала связи link может снизить выживаемость узлов и каналов в сети связи до минимального уровня как 69,69%, вызывают приращение задержки системы на 2,1635 и вызывают паралич на 35,07% в узлы и звенья электрической сети. Также отмечается, что некоторые сбои в работе канала не повлияют на остальные сети связи и электропитания за пределами неисправного звена. Это поскольку при каскадных сбоях сеть связи учитывает перегруженное состояние ссылки, перераспределяет трафик на вышедшие из строя и перегруженные ссылки. Более того, перегруженный ссылки могут поддерживать работу в течение короткого периода времени, прежде чем выйти из строя тем самым улучшая работу системы. устойчивости в той или иной степени. Кроме того, канал связи, вызывающий максимальную приращение задержки не обязательно может привести к наименьшему коэффициенту выживаемости узлов/каналов в сети связи или к наибольшей частоте отказов в узлах /каналах энергосети. Однако, интенсивность отказов узлов/звеньев в сетях связи и электроснабжения соответственно высока похотий. Например, при сбое канала 42 происходит наибольшее приращение задержки, равное 2,1635. В данный момент выживаемость узлов/каналов связи составляет 98,91%, а интенсивность отказов мощность узлов/каналов составляет 3,46%. Это связано с тем, что отказ канала 42 меняет путь с узла связи 27 с центром управления от исходного пути 27 26 40 44 к 27 17 16 43 44, что приводит к задержке связи. Частота неудач в общении узел 27 составляет 36,06%. Однако удаление канала 42 не вызывает сбоя или перегрузки в других каналах, поэтому имеется 45 рабочих каналов, а количество эффективных узлов связи остается неизменным по сравнению с тем, что было до неисправности. Благодаря связующим отношениям, Интенсивность отказов энергоузла 27 также составляет 36,06%, что в конечном итоге приводит к выходу из строя энергоузла узел 27.




(a)



(b)

Рисунок 8. Продолжение.



(с)


Рисунок 8. Влияние первоначальных сбоев на киберфизическую систему. (a,b) показывают влияние каждого отказа канала связи на надежность и приращение задержки системы связи, а (с) показывает влияние каждого отказа канала связи на физическую энергосистему.

4.3. Влияние стратегий атаки


В предыдущем разделе анализировалось влияние N-1, вызванное отказом одного канала связи. По мере увеличения количества неисправных линий различные начальные наборы неисправных линий будут оказывать различное влияние на систему. Поэтому, основываясь на структурных и электрических характеристиках, мы используем как атаку случайной линии, так и атаку критической линии для удаления каналов связи с целью взаимного анализа влияния различных стратегий атаки на передачу данных в сети электропитания и связи.

Стратегия атаки на критическую линию выводится из их рейтинга важности централизации мощности в энергосети. Из-за неопределенности стратегии случайной атаки каждая ошибочная линия в стратегии случайной атаки генерируется случайным образом, а результаты усредняются после 50 независимых запусков.


Как показано на рисунке 9, по сравнению с случайными атаками, CPPS демонстрирует высокую уязвимость при атаках на критические линии. При атаках на критические линии, даже если предварительно принять во внимание перераспределение информационного потока из-за перегрузки канала, сеть все равно получает значительный ущерб. Это связано с тем, что выход из строя критических линий нарушает пути передачи информации в центр управления, предотвращая загрузку информации о сбоях питания. Следовательно, центр управления не может отреагировать, а узлы-источники, передающие информацию в сеть связи, вызовут выход из строя связанных с ними узлов, тем самым расширяя масштаб неисправности и усугубляя распространение каскадных отказов и коллапс системы.




(a)



(б)



(c)



(г)

Рисунок 9. Влияние стратегий атаки на киберфизическую систему. (a–d) иллюстрируют взаимосвязь между метриками оценки связанной сети и количеством вышедших из строя каналов связи при двух различных стратегиях атаки (случайная атака и преднамеренная атака). В частности, (a) показана взаимосвязь между уровнем живучести узлов/звеньев в энергетической сети связи и количеством вышедших из строя каналов связи, (б) показана взаимосвязь между частотой отказов узлов/звеньев в энергетической сети связи и количеством вышедших из строя каналов связи. (c, d) соответственно изображают тенденцию увеличения задержки в системе при случайной и преднамеренной атаке.

5. Выводы

В этой статье исследуется динамическое распространение каскадных отказов в CPPS. Сначала анализируется взаимосвязь между сетью связи и физической сетью электропитания, и на основе сети электропитания генерируется структура топологии соответствующей системы связи. Затем в сети связи устанавливается модель распределения перегрузки для потока информации для устранения перегрузок, возникающих в результате сбоев. В энергосети устанавливается модель распределения нагрузки и мощности, основанная на взаимосвязи потоков мощности, чтобы справиться с ложностью расчета потоков мощности из-за сбоев. Чтобы более точно описать отказы узлов/линий, вызванные перетоками мощности из-за неисправностей, традиционная теория перколяции усовершенствована и позволяет создать модель распространения отказов для связанных сетей.

В целом, в этой статье всесторонне рассмотрены как электрические характеристики физической энергосистемы, так и характеристики передачи информации о мощности сети связи при установлении модели связи. Это улучшает компактную сетевую модель как топологическую структуру, так и функциональные характеристики, а также строит модель каскадных отказов, которая более точно отражает реальные сценарии. Большинство существующих исследований основаны на теории перколяции и анализируют только каскадный отказ. Процесс CPPS с точки зрения топологической целостности. Этот подход терпит неудачу в реализации улавливания островных явлений в работе энергосистемы, что требует усовершенствования теории перколяции.

В ходе моделирования анализируется явление неисправных линий на перегрузочную способность линий связи, передачу данных, живучесть сети и физическую мощность. Частота отказов сети. Результаты показывают, что даже небольшое увеличение пропускной способности канала может значительно повысить надежность сети. Кроме того, снижается производительность системы. При атаке звеньев в критических топологических позициях сети связи, что приводит к увеличению задержки системы по сравнению с лучшими атаками и вызывает Сеть информационного уровнях нет раньше.

Таким образом, эти результаты дают ценную информацию для будущего планирования энергетических сетей. Однако эти исследования основаны на условиях после аварии и рассматривают только взаимодействия между узлами как нормальный, так и полный отказ без учета диспетчеризацию потока мощности центра управления. В действительности процесс взаимодействия с иловых узлов и информационных узлов чрезвычайно сложен и часто анализируется только качественно. Более того, по сравнению Для распределения потока мощности планирование потока информации относительно просто. Сокращение возникновение неисправностей от источника кибер-стороны является более эффективным и надежным решением вместе с созданием механизма сопротивления каскадным отказам на стороне электросети. Поэтому наши будущие исследования будут сосредоточены на распределении критически важных информационных потоков по надежным каналам трактов в условиях перегрузки линий связи для обеспечения доступности и снижения вероятности каскадных сбоев, вызванных прерываниями связи.

Вклад автора: концептуализация XL и YL; Методология XL и YL; Письмо — оригинал черновой, XL; Написание — рецензирование и редактирование, YL и TX. Все авторы прочитали и согласились с условиями. Опубликованный вариант рукописи.

Финансирование: Работа выполнена при поддержке Национального фонда естественных наук Китая. Грант 62062068 и Программа молодых академических и технических лидеров провинции Юньнань в рамках Гранта 202305AC160077.

Заявление об отсутствии данных. Исходные материалы, представленные в исследовании, включены в статью, дополнительные вопросы можно направить с ответствующему автору.

Благодарности: Спасибо за помощь Вычислительному центру искусственного интеллекта Куньмина.

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Сокращения и номенклатура

СЦЭС	Киберфизическая энергосистема;
	Потребность в информационном потоке посылке e_{ij} ;
	Отношение пропускной способности канала к нагрузке канала;
Фидж q_{ij}	Порог отказа ссылки;
ВП	Комплекты с иловых узлов;
Эп	Комплекты линий электропередачи;
μ_{ij}	Значение модульности объединенного объединения двух сообществ;
ци	Доля мощности генератора i в общей мощности системы;
δ	Способность канала обрабатывать дополнительный поток информации;
ки	Степень узла i ;
θ	Параметр, регулирующий поток информации;
$L_{c,ij}$	Объем информации, передаваемой посылке e_{ij} ;
CC_{ij}	Пропускная способность канала e_{ij} ;

$S_{c,ij}^{Max}$	Максимальный поток, который может выдержать канал e_{ij} ;
$\alpha_{e_{ij}}$	Вес ссылки e_{ij} ;
α	Коэффициент мощности;
β	Коэффициент мощности;
$\min(S_m, S_n)$	Вес между потоками одной линии;
$P_{ij,m}$	Часть потока мощности по линии e_{ij} , исходящая от генератора m ;
$r_{ij,n}$	Часть потока мощности по линии e_{ij} , направленная на нагрузку n ;
P_{ij}	Активная мощность по линии e_{ij} ;
PL_n	Активная нагрузка в узле нагрузки n ;
A_{unm}^{-1}	Элементы матрицы расщепления обратного порядка;
g_m	Активный выход узла генератора m ;
$\phi_{e_{ij}}$	Поток между ребром e_{ij} в энергосети;
$L_{\phi(ij)}$	Словесная нагрузка на ребре e_{ij} в электросети;
$S_{\phi(ij)}$	Мощность края e_{ij} в электросети;
γ	Параметр допуска;
α_k	Стратегия расщепления в перегруженном филиале;
ϕ_k	Скорректированная степень выживания узла/канала после сбоя сети связи;
T	Приращение задержки передачи;
ϕ_p	Скорость отказа узла/канала после сбоя электросети.

Рекомендации

1. Абдельмаляк, М.; Венкатараманан, В.; Макван, Р. Обзор методов моделирования киберфизических энергосистем для энергетики будущего. *сис. тем.* IEEE Access 2022, 10, 99875–99896. [\[Перекрестная ссылка\]](#)

2. Ли, Ю; Ван, Б.; Ван, Х.; Ма, Ф.; Ма, Х.; Чжан, Дж.; Чжан, Ю; Мохамед, М; Санусетс. Эффективная взаимосвязанность от узла границы. Анализ сетей и уязвимости цифровых связанных электросетей. *Межд. Пер. Электр. Энергетическая система.* 2022, 2022, 5820126. [\[Перекрестная ссылка\]](#)

3. Гао, Х.; Гэн, М.; Чжи, КТ; Чжан, Х. Стохастическая модель динамики каскадных отказов в киберфизических энергосистемах. *IEEE Сист. Дж.* 2020, 14, 4626–4637. [\[Перекрестная ссылка\]](#)

4. Лян, Г.; Веллер, СР; Чжао, Дж.; Луо, Ф.; Донг, З. Ю. Отключение электроэнергетики в Украине в 2015 году: последствия атак с внедрением ложных данных. *IEEE Пер. Системы питания* 2016, 32, 3317–3318. [\[Перекрестная ссылка\]](#)

5. Чжао, К.; Ци, Х.; Хуа, М.; Лю, Дж.; Тиан, Х. Обзор недавних отключений электроэнергетики и прогнозирования. В материалах CIREД 2020 Берлинский семинар (CIREД 2020), онлайн-конференция 22–23 сентября 2020 г.; ИЭПТ Стивенейдж, Великобритания 2020 г.; Том 2020; стр. 312–314.

6. Ву, Дж.; Чен, З.; Чжан, Ю; Ся, Ю; Чен, Х. Последовательное восстановление сложных сетей, страдающих от каскадных отключений электроэнергетики. *IEEE Транс. Сеть. наук. анг. л.* 2020, 7, 2997–3007. [\[Перекрестная ссылка\]](#)

7. Гэн, К.; Ву, Дж.; Тиан, Э. Стохастическое управление Н, инициируемое событиями, для сетевых систем в условиях атак типа «отказ в обслуживании». *IEEE Пер. Сист. Человек Киберн. Сист.* 2021, 52, 4200–4210. [\[Перекрестная ссылка\]](#)

8. Ху, С.; Ю, Д.; Хан, Квинсленд; Се, Х.; Чен, Х.; Доу, К. Управление по событиям на основе наблюдателя для сетевых линейных систем. *Подвержен атакам типа «отказ в обслуживании».* IEEE Транс. Киберн. 2020, 50, 1952–1964. [\[Перекрестная ссылка\]](#)

9. Булдырев С.В.; Паршани, Р.; Пол, Г.; Стэнли, НЕ; Хэвлин, С. Катастрофический каскад боев взаимосвязанных сетей. *Природа* 2010, 464, 1025–1028. [\[Перекрестная ссылка\]](#)

10. Хуан, Х.; Гао, Дж.; Булдырев С.В.; Хэвлин, С.; Стэнли, Х. Э. Надежность взаимосвязанных сетей при целенаправленной атаке. *Физ. Ред. Е—Стат. Нелинейная физика мягких веществ.* 2011, 83, 065101. [\[CrossRef\]](#) [\[PubMed\]](#)

11. Цао, Ю; Лю, Р.Р.; Цзя, СХ; Ванг, Б.Х. Проникновение в многоуровневые ложные сети с осознанностью и взаимосвязанностью топологические структуры. *Коммун. Нелинейная наука. Число. Симул.* 2021, 92, 105492. [\[CrossRef\]](#)

12. Чен, Л.; Ю, Д.; Доу, К.; Ченг, З.; Чен, Дж. Устойчивость киберфизических энергетических систем при каскадных отказах: выживание взаимосвязанных кластеров. *Межд. Дж. Электр. Энергетическая система.* 2020, 114, 105374. [\[CrossRef\]](#)

13. Пан, Х.; Ли, Х.; На, К.; Цао, Р. Моделирование и анализ каскадных боев в киберфизических энергосистемах в различных условиях. *стратегии с опражнения* IEEE Access 2022, 10, 108684–108696. [\[Перекрестная ссылка\]](#)

14. Цзяньфэн, Д.; Цзянь, К.; Цзин, В.; Сюэсун, В. Метод оценки уязвимости киберфизической энергосистемы с учетом выход из строя электросетевой инфраструктуры. В материалах конференции IEEE по устойчивой энергетике и энергетике 2019 года (ISPEC), Пекин, Китай, 21–23 ноября 2019 г.; IEEE: Пискагуэй, Нью-Джерси, США 2019 г.; стр. 1492–1496.

15. Тиан, М.; Донг, З.; Гонг, Л.; Ван, Х. Стратегия усиления устойчивости энергосистем с учетом кибертопологии взаимосвязанности. *Надежный. анг. л. Сист. Саф.* 2024, 241, 109644. [\[CrossRef\]](#)

16. Чен, Л.; Ю, Д.; Доу, К.; Се, Х.; Ли, С.; Чжао, Н.; Чжан, Т. Влияние каскадного сбоя на распределение электроэнергии и данные передачи в киберфизических энергосистемах. *IEEE Транс. Сеть. наук. анг. л.* 2023, 11, 1580–1590. [\[Перекрестная ссылка\]](#)

17. Чжун, Дж.; Чжан, Ф.; Ян, С.; Ли, Д. Восстановление взаимосвязанной сети против каскадных перегрузок. *Физ. Стат. Мех. Это приложение.* 2019, 514, 884–891. [\[Перекрестная ссылка\]](#)

18. Дин, Д.; Ву, Х.; ЮХ.; Ван, Х.; Ян, Л.; Ван, Х.; Конг, Х.; Лю, К.; Лу, З. Оценка уязвимости киберфизической энергосистемы на основе усовершенствованной модели каскадных отказов. *Дж. Электр. инж. Техн.* 2024, 1–12. [\[Перекрестная ссылка\]](#)
19. Ван, С.; Гу, Х.; Чен, Дж.; Чен, К.; Хуанг, Х. Стратегия повышения устойчивости киберфизических систем с слабыми взаимозависимостями. *Надежный. инж. Сист. Сф.* 2023, 229, 108837. [\[CrossRef\]](#)
20. Гасеми, А.; де Меер, Х. Устойчивость взаимозависимых электросетей и сетей связи к каскадным отказам. *IEEE Транс. Сеть. наук. инж.* 2023, 10, 1919–1930. [\[Перекрестная ссылка\]](#)
21. Цао, Р.; Донг, Х.; Ван, Б.; Лю, К. Обсуждение защиты и каскадных отключений с точки зрения связи. В материалах Международной конференции по современной автоматизации и защите энергосистем 2011 г., Пекин, Китай, 16–20 октября 2011 г.; IEEE: Пискацзуй, Нью-Джерси, США, 2011 г.; Том 3, стр. 2430–2437.
22. Чжан Г.; Ши, Дж.; Хуанг, С.; Ван, Дж.; Цзян, Х. Модель каскадного отказа с учетом рабочих характеристик коммуникационного уровня. *IEEE Access* 2021, 9, 9493–9504. [\[Перекрестная ссылка\]](#)
23. Гао, Х.; Гэн, М.; Чен, К.Т. Анализ устойчивости киберфизических энергосистем с учетом взаимозависимости структур, операций и динамического поведения. *Физ. Стат. Мех.* Это приложение. 2022, 596, 127215. [\[CrossRef\]](#)
24. Ван, Ф.; Ли, Д.; Сюй, Х.; Ву, Р.; Хэвлин, С. Свойства перколяции в модели дорожного движения. *Еврофиз. Летт.* 2015, 112, 38001. [\[CrossRef\]](#)
25. Сабери, М.; Хамеддог-адам, Х.; Ашфак, М.; Хосейни, ЮР; Гу, З.; Шафи, С.; Наир, диджей; Диксит, В.; Гарднер, Л.; Уоллер, ST; и другие. Простой процесс заражения описывает распространение пробок в городских сетях. *Наг. Коммун.* 2020, 11, 1616. [\[CrossRef\]](#)
26. Лю, В.; Лян, К.; Сюй, П.; Дэн, Ю; Ван, Дж.; Ван, В. Идентификация критической линии в энергосистемах на основе взаимосвязи потоков. *Учеб. CSEE* 2013, 33, 90–98.
27. Ван, Т.; Сан, К.; Гу, Х.; Цинь, Х. Моделирование и анализ уязвимости объединенной сети электроэнергетической связи. *Учеб. CSEE* 2018, 38, 3556–3567.
28. Ньюман М.Е. Нахождение структуры сообществ с помощью собственных векторов матриц. *Физ. Ред. E—Стат. Нелинейный мягкий Материя Физика* 2006, 74, 036104. [\[CrossRef\]](#)
29. Чен, СУ; Чжао, Ю; Гао, Дж.; Стэнли, Х.Э. Нелинейная модель каскадного отказа в сложных сетях с учетом перегруженных ребер. *наук. Отчет* 2020, 10, 13428. [\[CrossRef\]](#)
30. Стауффер, Д.; Ахарони, А. Введение в теорию перколяции; Тейлор и Фрэнсис: Абингдон, Великобритания, 2018 г.
31. Моттер А.Е.; Лай, ЮК. Каскадные атаки на ложные сети. *Физ. Ред. E* 2002, 66, 065102. [\[CrossRef\]](#)
32. Хан, Ю; Го, К.; Чжу, Б.; Сюй, Л. Модель каскадных боев в киберфизической энергосистеме на основе усовершенствованной теории перколяции. *Автомат. Электр. Система питания* 2016, 40, 30–37.

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



Статья

Практическая методология оценки безопасности энергосистемы Операции с учетом неопределенности

Нхи Тхи Ай Нгуен ¹, Динь Дуонг Ле ^{1,*}, Ван Дуонг Нго ¹, Ван Кьен Фам ¹ и Ван Ки Хюнь ²

¹ Факультет электротехники, Данангский университет — Университет науки и технологий, Дананг 550000, Вьетнам; ntanhi@dut.udn.vn (НТАН); nvduong@dut.udn.vn (ВДН); pvkien@dut.udn.vn (ВКП)

² Университет Дананга, Дананг 550000, Вьетнам; hvky@ac.udn.vn *
Переписка: ldduong@dut.udn.vn

Аннотация: Сегодня возобновляемые источники энергии (ВИЭ) все активнее интегрируются в энергосистемы. Это означает добавление дополнительных источников неопределенности в энергосистему. Чтобы справиться с неопределенностью входных случайных величин (RV) в задачах расчета и анализа энергосистемы, были введены методы вероятностного потока мощности (PPF), которые доказали свою эффективность. В настоящее время, хотя для решения проблемы PPF предложено множество методов, метод моделирования Монте-Карло (MCS) по-прежнему считается методом с наибольшей точностью, и его результаты используются в качестве эталона для оценки других методов. Однако MCS часто требует очень высоких вычислительных затрат, что затрудняет практическое применение, особенно в крупномасштабных энергосистемах. В данной статье предлагается усовершенствованный метод кластеризации данных для обработки входных данных RV, чтобы уменьшить вычислительную нагрузку на решение задачи PPF, сохраняя при этом приемлемый уровень точности. Предложенный метод может быть эффективно применен для решения практических задач в эксплуатационном горизонте энергосистем. Разработанный подход протестирован на модифицированной шинной системе IEEE-300, что свидетельствует о хорошей производительности по сокращению времени.

Ключевые слова: вероятностный поток мощности; система питания; Возобновляемая энергия



Цитирование: Нгуен, НТА; Ле, Д.Д.;

Нго, В.Д.; Фам, В.К.; Хюнь, ВК

Практическая методология оценки
безопасности работы энергосистемы с
учетом неопределенности.

Электроника 2024, 13, 3068. <https://doi.org/10.3390/electronics13153068>.

Академический редактор: Ахмед Абу-Сиада

Поступила: 26 июня 2024 г.

Пересмотрено: 31 июля 2024 г.

Принято: 31 июля 2024 г.

Опубликовано: 2 августа 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

В процессе эксплуатации энергосистемы параметры режима работы, такие как напряжение на шинах, мощность, передаваемая по ветвям и т. д., необходимо регулярно рассчитывать для оценки безопасности системы путем сравнения параметров с их допустимыми пределами. В случае возникновения угрозы безопасности должны быть предложены разумные решения для ее устранения. Детерминированный поток мощности (DPF) является одним из важнейших инструментов для эксплуатации и планирования энергосистемы. Тем не менее, в процессе вычислений традиционный подход использует фиксированные значения узловых впрысков мощности (от выработки электроэнергии, нагрузки и т. д.) и известную структуру сети, так что источники неопределенности, связанные с этими факторами, не учитываются. Это основное ограничение традиционного метода потока мощности.

Чтобы преодолеть вышеупомянутый недостаток, был предложен PPF, который стал очень эффективным инструментом расчета. Нагрузка, выработка электроэнергии на установке и работа такого элемента, как линия, трансформатор и т. д., могут подчиняться определенным правилам вероятности. В частности, для современных энергетических систем, когда к системе подключены дополнительные ВИЭ, такие как солнечная, ветровая энергия и т. д., моделирование нестабильности возобновляемых источников энергии является очень сложной задачей. Переменяемость часто меняется очень быстро и стохастически, увеличивая уровень неопределенности в системе. Следовательно, метод расчета должен иметь возможность интегрировать неопределенности в процесс расчета. При использовании методов ППФ выходные данные, т. е. напряжение на шинах, передаваемые по ветвям ПП и т. д., также изменяются случайным образом по закону распределения вероятностей [1]. Анализ PPF позволяет оценить вероятность перегрузки линии, вероятность повышенного/пониженного напряжения и т. д. Отсюда, в за

характеристики системы и серьезность нарушения, оператор может рассмотреть и предложить соответствующие решения для повышения безопасности системы.

Подход PPF был впервые представлен Борковской в 1974 году [2], и с тех пор по всему миру было предложено несколько исследовательских работ по PPF. В целом методы расчета коэффициента мощности с использованием метода PPF можно разделить на три основные категории: численные, аналитические и аппроксимационные подходы.

Аналитический подход [3–6] использует алгоритмы и аналитические методы, такие как методы свертки и кумулянта. Применение этих аналитических методов в сочетании с взаимосвязью входных и выходных данных задачи PPF позволяет определить функцию распределения выходных RV, таких как передача мощности в линии, узловое напряжение, фазовый угол и т. д. в соответствии с системой. параметры, например, полное сопротивление линии, полное сопротивление трансформатора и т. д., и распределения вероятностей входных RV нагрузки и выработки электроэнергии от традиционных генераторов и ВИЭ, а также рабочего состояния устройств. Взаимосвязь между входными и выходными данными задачи расчета PF является нелинейной. Тем не менее, аналитический метод хорошо работает при линейной зависимости между входными и выходными данными задачи. Следовательно, связь, во-первых, необходимо линеаризовать с помощью метода расширения, например, расширения Тейлора. Одним из выдающихся преимуществ аналитического подхода является то, что он может давать очень быстрые результаты. Среди кумулянтных подходов и подходов свертки метод свертки является более трудоемким в вычислительном отношении, чем кумулянтный. Следовательно, в настоящее время кумулянтный подход более популярен, чем подход свертки. Чтобы получить функции распределения для выходных RV, кумулянтный подход часто используется одновременно с методами расширения, такими как расширение Грама-Шарлье или Корниша-Фишера [4]. Благодаря преимуществу быстрых вычислений аналитический подход может быть применен на практике для крупномасштабной энергосистемы. Тем не менее, аналитический подход имеет некоторые недостатки. Во-первых, на точность аналитического подхода существенно влияет использование методов, линеаризующих зависимость входа и выхода, особенно когда входная СВ изменяется в широком диапазоне, например, в случае с ВИЭ. Во-вторых, аналитический подход использует методы расширения, которые могут хорошо работать в случае, когда функции распределения входных RV являются либо распределением Гаусса, либо близкими к распределению Гаусса. Фактически, функции распределения входных RV задачи PPF для энергосистемы на практике часто следуют негауссовому распределению, поэтому достигнутые результаты будут ограничены. Для возможности интеграции дискретных функций распределения входных СВ в процесс расчета предлагается метод фон Мизеса [1].

Типичным для группы аппроксимационных подходов при расчете ППФ является подход точечной оценки [7,8]. В этом подходе входной RV разлагается на последовательность пар значений и весов. Затем момент выходного RV вычисляется как функция входного RV, а затем получается выходная функция распределения RV. Подход точечной оценки может обеспечить относительно быстрые результаты. Более того, в отличие от аналитического подхода, этот подход использует нелинейную связь между входными и выходными данными задачи вычисления ПФ. Однако основным ограничением подхода точечной оценки является то, что его точность снижается с увеличением порядка момента. Другим недостатком является то, что требуемое время вычислений значительно увеличивается по мере увеличения количества входных RV.

Типичным численным подходом является MCS [9–14]. В MCS входные RV выбираются, а затем для всех выборок выполняется расчет DPF. Он повторяет моделирование с очень большим количеством образцов для получения высокоточного результата. MCS использует нелинейную зависимость между входными и выходными данными задачи PF, как и традиционный подход. Основное преимущество подхода MCS заключается в том, что он дает очень точные и надежные результаты. Более того, распределения вероятностей входных RV в MCS легко представить. Однако самым большим недостатком является большой объем вычислений и относительно большое время вычислений, что затрудняет применение к практической крупномасштабной энергосети. Чтобы уменьшить вычислительную нагрузку метода MCS, предлагается несколько алгоритмов кластеризации для уменьшения количества выборок, а затем DPF запускается для каждого кластера вместо запуска его для всех выборок. В [15] предлагается использовать алгоритм PSO для

задача кластеризации, а K-средние используются в [16,17]. Каждый алгоритм кластеризации имеет свои слабые стороны. Для PSO скорость итеративной сходимости скромна, и он часто застревает на локальных оптимумах при работе с многомерными наборами данных. Алгоритм K-средних чувствителен к выбору k , и трудно найти оптимальный k для данного набора данных. Более того, K-средние плохо масштабируются для решения больших задач, поэтому в настоящем исследовании основное внимание уделяется этой проблеме.

Из приведенного выше анализа видно, что каждый подход PPF имеет свои особенности, особенности, преимущества и недостатки.

Помимо приведенного выше обзора PPF для решения различных проблем, связанных с неопределенностью, также были обнаружены недавние достижения. В [18] разработан двухэтапный метод робастной скоординированной диспетчеризации для мультиэнергетических микросетей, позволяющий смягчить все негативные эффекты различных неопределенностей, связанных с энергией ветра и нагрузками. Интервальный метод используется в [18] для характеристики неопределенностей. В [19] предложен регион гарантированных выбросов углекислого газа (CCEOR) интегрированных энергетических систем (IES). Разработанный метод преобразует предложенную неопределенную нелинейную модель CCEOR в детерминированную выпуклую смешанно-целочисленную модель CCEOR. В [20] для учета различных типов неопределенностей, связанных с последствиями стихийных бедствий, экстремальных явлений, нагрузок и возобновляемой генерации, меры как до восстановления, так и в режиме реального времени координируются с помощью двухэтапного метода стохастического программирования.

Основные положения данной статьи резюмируются следующим образом: (1) Основная цель данного исследования – разработать подход к расчету PPF, который обеспечивает определенный уровень точности по сравнению с MCS, но который должен давать очень быстрые результаты, близкие к «реальному времени». «работа энергосистемы. Чтобы использовать преимущества точности метода MCS при одновременном сокращении трудоемкости и объема вычислений, предлагается метод кластеризации в реальном времени в сочетании с MCS при расчете PPF. Применяемый метод кластеризации прост, но эффективен и пригоден для практического применения. Большое количество выборок входных RV задачи расчета PPF с использованием MCS значительно и эффективно сокращается, поэтому расчет PPF дает быстрые результаты. Благодаря этой выдающейся особенности подход PPF может применяться к крупным энергетическим системам на практике и в течение срока эксплуатации. (2) Кроме того, в этой статье также подробно представлено обсуждение применения методов PPF при расчете и анализе энергосистем. Это дает более четкое и интуитивное представление о применении анализа PPF как при планировании, так и при эксплуатации энергосистем. Также отмечаются текущие ограничения методов PPF в целом, чтобы обеспечить темы для будущих исследований.

Остальная часть этой статьи структурирована следующим образом. В разделе 2 представлена разработанная методология, а результаты, полученные с помощью разработанного подхода, обсуждаются в разделе 3. В разделе 4 дается дальнейшее обсуждение применимости различных методов PPF в задачах анализа энергосистем. Заключительные замечания приведены в разделе 5.

2. Методика 2.1.

Методика кластеризации в реальном

времени Кластеризация — это разделение данных на несколько групп так, чтобы точки данных в одной группе имели схожие характеристики друг с другом и отличались от точек данных в других группах. По сути, это задача разделения данных в наборе данных на основе сходств и различий между ними. Среди методов кластеризации K-средние известны как наиболее популярные и применяются во всех областях благодаря своей простоте, эффективности, масштабируемости и простоте реализации. Он может эффективно обрабатывать большие наборы данных, что делает его практичным выбором для множества приложений. Комплексный обзор применения кластеризации K-средних в современных энергосистемах представлен в [21]. Алгоритм кластеризации K-средних — это тип машинного обучения без учителя, который делит немаркированный набор данных на k различных кластеров с помощью итеративного алгоритма.

Алгоритм K-средних реализован следующим образом: Шаг 1:

Случайным образом выберите k точек или центроидов из рассматриваемых данных для инициализации групп или кластеров;

Шаг 2. Для каждой точки набора данных вычислите расстояние между точкой и каждым из k центроидов; назначьте каждую точку ближайшему центроиду, чтобы сформировать k кластеров;

Шаг 3. Замените центроид для каждого кластера средним значением всех назначенных точек данных. в кластер;

Шаг 4. Повторяйте шаги 2 и 3 до тех пор, пока центроиды не перестанут существенно меняться или после заранее выбранного максимального количества итераций. Полученные результаты — это последние центроиды кластера и точки данных, назначенные кластерам.

Хотя метод К-средних имеет множество преимуществ, он имеет и некоторые недостатки, которые могут повлиять на его применимость и производительность. Считается, что алгоритм К-средних не обладает хорошей масштабируемостью для решения больших задач. Он чувствителен к выбору k , и трудно найти оптимальный k для данного набора данных. К-средние сходятся к локальному минимуму, поэтому разные инициализации приведут к разным результатам.

К-средние могут занять очень много времени при работе с большими наборами данных. Для набора данных, включающего n точек данных, его необходимо запустить $O(nkT)$ раз, чтобы вычислить расстояния между n точками данных и каждым из k центроидов (T — количество итераций) [22]. В алгоритме К-средних каждая итерация занимает время, пропорциональное k и n . Это объясняет, почему алгоритм К-средних имеет плохую масштабируемость. Время работы будет увеличиваться с увеличением n или k , или того и другого. Следовательно, его эффективность можно значительно повысить за счет уменьшения времени выполнения, связанного с n . Чтобы решить проблему плохой масштабируемости, в [22] авторы развивают подход K-means-lite, который может получить целевые центроиды за время $O(1)$ по отношению к n и демонстрирует улучшенный коэффициент ускорения. по мере увеличения k и n . Также было показано, что точность увеличивается. Используется метод статистического вывода, при котором k -центроиды рассчитываются с использованием нескольких небольших выборок вместо повторного исчерпывающего сравнения между центроидами и точками данных. Эта идея исходит из интуитивного расширения классической центральной предельной теоремы. В частности, его использование не требует специальных структур данных, не требует хранения вычисленных расстояний в памяти и не требует повторных исчерпывающих присваиваний. Показано, что использование K-means-lite обеспечивает значительный прирост эффективности и позволяет решать большие наборы данных в режиме реального времени; в этой статье это называется расширенной кластеризацией данных (ADC) [22].

2.2. Представление входных неопределенностей

В данной статье для учета неопределенностей относительно выходной мощности генераторов, нагрузок и т. д., а также параметров компонентов они представлены вероятностными распределениями. На основе их исторических данных можно оценить распределение. Их также можно обеспечить с помощью методики прогнозирования, особенно при решении оперативных задач.

- Генерация ветра. Для

моделирования скорости ветра обычно используется распределение Вейбулла [23]. Ее функция плотности вероятности (PDF) представлена как:

$$e(v) = \frac{h}{c} \cdot \left(\frac{v}{c} \right)^{\frac{h}{c}-1} \cdot \text{ОПЫТ} \cdot \frac{v}{c} \quad (1)$$

где h : параметр формы; c : параметр масштаба; v : скорость ветра.

Характеристическую кривую ветряной турбины можно оценить по соотношению мощность ветра – скорость ветра. данные парных измерений [24]. Его также можно смоделировать кусочной функцией следующим образом:

$$P_{wo}(v) = \begin{cases} 0 & v < v_{ci} \text{ или } v > v_{co} \\ P_w \frac{v - v_{ci}}{v_r - v_{ci}} & v_{ci} < v < v_r \\ P_w & v_r < v < v_{co} \end{cases} \quad (2)$$

где v_{ci} , v_{co} и v_r — скорости включения, отключения и номинальная скорость ветра соответственно; P_{wr} и P_{wo} — номинальная мощность и мощность ветрогенерации соответственно.

• Солнечная генерация

Распределение солнечной радиации можно оценить по данным ее наблюдений. Это также обычно представлено бета-распределением [25], как:

$$f(r) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \cdot \frac{r^{\alpha-1}}{r_{\max}^{\alpha-1}} \cdot \left(1 - \frac{r}{r_{\max}}\right)^{\beta-1} \quad (3)$$

где r и $r_{\max}$ — реальная и максимальная солнечная радиация соответственно; α и β — два основных параметра распределения; $\Gamma(\cdot)$ — известная гамма-функция.

$$P_{vo}(r) = \begin{cases} \frac{P_{vr} \cdot r^2}{r_{cstd} \cdot r} & r < r_c \\ \frac{P_{vr}}{r_c} & r \geq r_c \end{cases} \quad (4)$$

Первое утро r_c — первый день

где r_c — излучение в определенной точке; r_{std} — стандартное излучение (соответствующее стандартной среде); P_{vr} и P_{vo} — номинальная и выходная мощности фотоэлектрического блока соответственно. Солнечная генерация обычно должна работать в режиме коэффициента мощности, равном единице, т. е. ее реактивная мощность равна нулю.

• Нагрузка

Неопределенность каждой нагрузки обычно представляется гауссовым или нормальным распределением [1]. Функция нормального распределения является непрерывной функцией и одной из наиболее часто используемых функций в большинстве областей.

PDF нормального распределения выглядит следующим образом:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5)$$

где μ и σ — математическое ожидание (среднее значение) и стандартное отклонение соответственно.

Кумулятивная функция распределения (CDF) функции нормального распределения рассчитывается следующим образом:

$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \quad (6)$$

Для моделирования нагрузки ожидаемое значение (среднее) представляет собой ее базовую мощность, тогда как стандартная предполагается, что отклонение равно определенному проценту, например 10%, от среднего значения.

В дополнение к популярным распределениям вероятностей, показанным выше, которые очень подходят для представления неопределенностей от ВИЭ и нагрузок в энергосистемах, в настоящее время в области вероятностей и статистики существует несколько других распределений вероятностей и функций плотности, используемых для включения неопределенностей в расчеты. Проблема с ППФ. Другими словами, тот факт, что мы принимаем приведенные выше функции распределения РЭС и нагрузок, не теряет общности использования разработанного в данной работе метода ППФ.

2.3. Вероятностный поток мощности на основе расширенной кластеризации данных

Блок-схема предлагаемого подхода, то есть вероятностного потока мощности на основе расширенной кластеризации данных (ADCPF), используемого для вероятностной оценки безопасности, показана на рисунке 1. В блок-схеме на рисунке 1 основная часть, которая помогает значительно сократить время расчета находится в блоке АЦП.




Рисунок 1. Блок-схема предлагаемой вероятностной оценки безопасности.

3. Тесты и результаты

Применение разработанного подхода проиллюстрировано на модифицированной шине IEEE 300. Информация, необходимая для анализа DPF системы, т. е. электрической сети, шины, ветви, данные генератора, приведена в [26]. В систему входят 300 автобусов, 409 409 филиалов, 195 нагрузок и 69 генераторов. В этом испытании неопределенности как от нагрузок, так и от ветвей. Система модифицирована путем добавления 10 солнечных фотоэлектрических и 8 ветряных электростанций, модифицировано количество автобусов 10 солнечных фотоэлектрических заводов к автобусам, как показано в таблицах 1 и 2 соответственно.

Таблица 1. Информация о бета-распределениях солнечной фотоэлектрической энергии.

Автобус	Номинальная мощность	Параметр α	Параметр β
196	(МВт) 50	2,5	
198	80	1,6	9
203	40	1.2	6

Таблица 1. Информация о бета-распределениях солнечной фотоэлектрической энергии.

Автобус	Номинальная мощность (МВт)	Параметр α	Параметр β
196	50	2,5	8
198	80	1,6	9
203	40	1.2	6
204	60	2.2	8
215	70	3.2	7
217	50	3,5	10
221	35	4.2	11
229	90	2,8	8
245	65	1,9	7
246	95	3.1	8

Таблица 2. Информация о распределениях энергии ветра по Вейбуллу.

Автобус	Номинальная мощность (МВт)	Параметр масштаба	Параметр формы
118	90	10	2.4
121	80	15	1,6
126	100	11	2.4
142	50	14	1,5
154	40	20	2.2
156	60	28	1,8
159	70	16	1,7
161	95	12	2.3

Для простоты, но без потери общности, неопределенности нагрузок и предполагается, что ВИЭ известны с помощью методов прогнозирования. Неопределенность каждой нагрузки моделируется нормальным распределением с ожидаемым значением, равным базовому значению, и стандартное отклонение, равное 10% от ожидаемого значения. Солнечная фотоэлектрическая энергия предполагается, что неопределенность на каждом заводе соответствует бета-распределению, а его параметры заданы в таблице 1. Предполагается также, что распределения коррелируют с коэффициентом корреляции 0,7. В этом исследовании предполагается, что сценарий моделирования происходит в дневное время, с потенциальными условиями для производства солнечной фотоэлектрической энергии. Кроме того, мы предположим, что нагрузки, а также солнечные и ветряные электростанции не находятся в аномальных погодных условиях. Погодные условия (например, сильная жара, крупномасштабная зимняя буря и ураганы), чрезвычайно редкие явления (например, солнечное затмение) и катастрофы (например, войны, землетрясения и цунами). Некоторые из этих аномальных событий чрезвычайно сложно спрогнозировать при низких стандартах отклонения. Эти аномальные и редкие события также можно описать соответствующим распределением. функции и включены в задачу PPF. Однако этот вопрос выходит за рамки настоящего исследования и предназначено для рассмотрения в будущих исследованиях. Аналогично, неопределенность Предполагается, что выходная мощность каждой ветряной электростанции имеет распределение Вейбулла, при этом параметры приведены в таблице 2. Распределения коррелируют с коэффициентом корреляции 0,8.

В текущем тесте используется базовая мощность 100 МВА. Результаты MCS используются как ссылка для оценки результатов, полученных другими методами. Все тесты выполняются в Matlab (R2015b) на ПК с процессором Intel Core i5 2,53 ГГц и 4,00 ГБ ОЗУ. Вычисление PPF выполняется для достижения всех интересующих результатов выходных RV в условиях PDF и/или CDF. Для иллюстрации распределения числа отображаются выбранные выходные значения RV. На рисунке 2 показаны CDF реальных ПФ по ветвям 2–8.

Электроника 2024, 13, x НА ЭКСПЕРТИЗУ
Электроника 2024, 13, x НА ЭКСПЕРТИЗУ



Потому что трудно что-то наблюдать, отображая все результаты на одном и том же рисунке. Потому что крики трудно не только задевать, отображая все результаты на одном и том же рисунке, но и потому что результаты, соответствующие методу ADSPRF. Однако на самом деле показывать только результаты, соответствующие методу ADSPRF. Однако для иллюстрации показаны только результаты, соответствующие продемонстрировать эффективность, мы также сравниваем результаты PRF с использованием ADC с К_с среднего моделирования его эффективности. Мы также сравниваем результаты PRF с использованием ADC с К_с средних, как это и кристаллизацию.

Как обсуждалось в разделе 2.1, кластеризация К-средних может занимать очень много времени. Как показано на графике в разделе 2.1, кластеризация К-средних может быть намного быстрее при работе с большими наборами данных из-за проблем с плохой масштабируемостью. В отличие от К-средних, большие наборы данных из-за плохой масштабируемости. В отличие от К-средних, подход K-means++ был разработан [46], и он может давать результаты намного быстрее. Его точность имеет тенденцию к падению по сравнению с K, что позволяет получить быстрые результаты. Также было показано, что количество точек увеличивается по сравнению с методом К-средних. Таким образом, было показано увеличение этого показателя по сравнению с тем же количеством точек по сравнению с методом К-средних. Поэтому в этом тесте мы не фокусируемся на доказательствах точности метода ADP по сравнению с К-мы не фокусируемся на том, чтобы мы не концентрируемся на доказательстве точности метода ADP по сравнению с методом К-средних. Вместо этого основное внимание уделяется производительности времени обработки, там самым указывая метод. Вместо этого основное внимание уделяется производительности времени обработки, что указывает на то, что предлагаемый подход имеет хорошую применимость для решения проблем во временных рамках. Предложенный подход имеет хорошую применимость для решения задач во временных рамках.

Ускорения энергосистемы. В таблице 3 ясно показано, что подход ADCPPF может обеспечить работу системы энергосистем. В таблице 3 ясно показано, что подход ADCPPF может дать результат за несколько секунд по сравнению со стандартными методами. По сравнению с секундами, необходимыми для получения результата за несколько секунд, подает результат за несколько секунд по сравнению с сотнями секунд, необходимых MCS. В частности, как упоминалось ранее, для работы PPF требуется около десяти тысяч точек данных, K-MCS. В частности, как упоминалось ранее, для набора данных, включающего n точек данных, для запуска кластеризации K-средних требуется количество точек данных O(nK) (в котором T — числовая кластеризация требует количества времени, означает, что для запуска кластеризации требуется время, равное O(Tn) (где T — количество итераций). Время работы K-средней будет резко возрастать с увеличением n

и/или k. Модифицированная система шины IEEE 300 представляет собой крупномасштабную систему, поэтому на основе K-средств и/или k. Модифицированная система шин IEEE 300 представляет собой крупномасштабную систему, поэтому PPF работает очень тяжело и занимает много времени.

к. Модифицированная система шины IEEE 300 является крупномасштабной системой, поэтому PPF на основе К-средних работает очень тяжело и долго.

Таблица 3. Сравнение времени выполнения.

Метод	Время (с)
МКС	725
ADCPPF с 5 кластерами	2,64
ADCPPF с 10 кластерами	2,79
ADCPPF с 20 кластерами	2,98
ADCPPF с 30 кластерами	3.26
ADCPPF с 40 кластерами	3,47
ADCPPF с 50 кластерами	3,72
ADCPPF с 70 кластерами	4.21
PPF на основе К-средних с 5 кластерами	140
PPF на основе К-средних с 10 кластерами	420

Судя по рисункам 2, 3 и таблице 3, точность ADCPPF увеличивается (т.е. интуитивно соответствующая кривая на рисунках 2 и 3 более точно повторяет кривую MCS) и время, необходимое для выполнения метода, также увеличивается с увеличением количества кластеры. Сравнивая MCS с использованием К-средних и ADCPPF, К-средние представляют собой сложную задачу. случае и приводит к увеличению времени расчета намного больше, чем при использовании ADCPPF. Благодаря приведенному выше анализу показано, что метод ADCPPF имеет преимущество: как относительно высокая точность, так и значительно сокращенное время выполнения.

PPF может предоставить дистрибутивы для выходных автофургонов, которые хороши для безопасности энергосистемы. оценка. Вероятность пониженного/повышенного напряжения, перегрузки линии и т. д. может быть оценена. судил. Например, верхний предел реального ПФ ветвей 2–8 предполагается равным 445 МВт, т. е. соответствует вертикальной линии на рисунке 2, и вероятность того, что мощность переданное через ветвь превышение предела может быть вычислено как:

$$P\{P2 \ 8 > 445\} = 1,4\% \tag{7}$$

Аналогично вероятность того, что напряжение на рассматриваемой шине выйдет за пределы рабочего диапазона можно оценить. Однако в этом тесте напряжения на всех шинах системы (например, V89 на рисунке 3) находятся в пределах диапазона, т. е. [0,9, 1,1] о.е.


Результаты, полученные методом ADCPPF, могут помочь оператору системы оценивать рабочие состояния, чтобы принимать подходящие решения и предлагать решения для система.

4. Дальнейшее обсуждение применимости различных методов PPF.

Методы PPF могут быть выбраны для применения как в плановых, так и в эксплуатационных задачах. энергетических систем.

- Применение PPF в задачах планирования: метод MCS подходит для решения задач планирования. проблемы с длительными временными рамками (например, годами, сезонами, месяцами, неделями) или эксплуатационными планирование задач в течение нескольких дней. В таких случаях время достижения результаты не должны быть очень быстрыми. Помимо данных о конфигурации сети, данные по источникам (особенно ВИЭ) и нагрузкам, собранным в течение длительных периодов, т.е. месяцев, год или несколько лет используются для оценки PDF-файлов. Эти данные также могут быть использованы метод прогнозирования для получения результатов для работы системы. Если прогнозирования Метод основан на методе точечного прогноза, результаты прогноза представлены в виде установленное значение в каждый момент времени прогноза и соответствующая ошибка. Эти значения рассмотрели математическое ожидание и стандартное отклонение функции нормального распределения.

Действие актирования пометки **PDF** гарантирует, что если оператор не успеет принять решение о последовательных разбраждениях в течение 24 часов, то в горизонтальной области системы на сутки вперед. Системный оператор будет иметь очень четкую «картину» риска небезопасности системы, так как они могут предложить соответствующие решения. На основе сравнения критерия критического значения тока с предельно допустимым значением тока невозможно определить точку, в которой ток становится предельно допустимым, так как ток прохождения линии превысит допустимый значение.



Метод расчёта и анализа безопасности системы основан на информации и данных, полученных от случайных входных величин задачи, таких как нагрузки и выходные мощности ВИЭ. В результате с точки зрения распределения вероятностей вечерних выходов мощность источника солнечной энергии постепенно уменьшается, и в этом примере так же происходит с нагрузками. Однако выходных мощностей и нагрузок не предполагается делить по ветвям. В 19:00 этот источник больше всего вероятнее всего будет равен нулю, а значит, он тоже будет иметь нулевую вероятность, при которых нагрузка интересна представляется на графике нагрузок и других источников, если таковые имеются, а не от солнечной энергии в 20:00. Для представления вероятности в системе и в дальнейшем будет представлять исходные данные. Затем Формируется график, при котором вероятные нагрузки будут близки к нулю, поэтому mon-of-p2 . В случае, если вероятности нагрузки и мощности источника, то есть, вероятности, не являются непрерывными. Дополнительно длится около 1 часа, при этом вероятность в 20:00 уменьшается, и в 21:00, и в 22:00, и в 23:00, и в 24:00, и в 25:00, и в 26:00, и в 27:00, и в 28:00, и в 29:00, и в 30:00, и в 31:00, и в 32:00, и в 33:00, и в 34:00, и в 35:00, и в 36:00, и в 37:00, и в 38:00, и в 39:00, и в 40:00, и в 41:00, и в 42:00, и в 43:00, и в 44:00, и в 45:00, и в 46:00, и в 47:00, и в 48:00, и в 49:00, и в 50:00, и в 51:00, и в 52:00, и в 53:00, и в 54:00, и в 55:00, и в 56:00, и в 57:00, и в 58:00, и в 59:00, и в 60:00, и в 61:00, и в 62:00, и в 63:00, и в 64:00, и в 65:00, и в 66:00, и в 67:00, и в 68:00, и в 69:00, и в 70:00, и в 71:00, и в 72:00, и в 73:00, и в 74:00, и в 75:00, и в 76:00, и в 77:00, и в 78:00, и в 79:00, и в 80:00, и в 81:00, и в 82:00, и в 83:00, и в 84:00, и в 85:00, и в 86:00, и в 87:00, и в 88:00, и в 89:00, и в 90:00, и в 91:00, и в 92:00, и в 93:00, и в 94:00, и в 95:00, и в 96:00, и в 97:00, и в 98:00, и в 99:00, и в 100:00, и в 101:00, и в 102:00, и в 103:00, и в 104:00, и в 105:00, и в 106:00, и в 107:00, и в 108:00, и в 109:00, и в 110:00, и в 111:00, и в 112:00, и в 113:00, и в 114:00, и в 115:00, и в 116:00, и в 117:00, и в 118:00, и в 119:00, и в 120:00, и в 121:00, и в 122:00, и в 123:00, и в 124:00, и в 125:00, и в 126:00, и в 127:00, и в 128:00, и в 129:00, и в 130:00, и в 131:00, и в 132:00, и в 133:00, и в 134:00, и в 135:00, и в 136:00, и в 137:00, и в 138:00, и в 139:00, и в 140:00, и в 141:00, и в 142:00, и в 143:00, и в 144:00, и в 145:00, и в 146:00, и в 147:00, и в 148:00, и в 149:00, и в 150:00, и в 151:00, и в 152:00, и в 153:00, и в 154:00, и в 155:00, и в 156:00, и в 157:00, и в 158:00, и в 159:00, и в 160:00, и в 161:00, и в 162:00, и в 163:00, и в 164:00, и в 165:00, и в 166:00, и в 167:00, и в 168:00, и в 169:00, и в 170:00, и в 171:00, и в 172:00, и в 173:00, и в 174:00, и в 175:00, и в 176:00, и в 177:00, и в 178:00, и в 179:00, и в 180:00, и в 181:00, и в 182:00, и в 183:00, и в 184:00, и в 185:00, и в 186:00, и в 187:00, и в 188:00, и в 189:00, и в 190:00, и в 191:00, и в 192:00, и в 193:00, и в 194:00, и в 195:00, и в 196:00, и в 197:00, и в 198:00, и в 199:00, и в 200:00, и в 201:00, и в 202:00, и в 203:00, и в 204:00, и в 205:00, и в 206:00, и в 207:00, и в 208:00, и в 209:00, и в 210:00, и в 211:00, и в 212:00, и в 213:00, и в 214:00, и в 215:00, и в 216:00, и в 217:00, и в 218:00, и в 219:00, и в 220:00, и в 221:00, и в 222:00, и в 223:00, и в 224:00, и в 225:00, и в 226:00, и в 227:00, и в 228:00, и в 229:00, и в 230:00, и в 231:00, и в 232:00, и в 233:00, и в 234:00, и в 235:00, и в 236:00, и в 237:00, и в 238:00, и в 239:00, и в 240:00, и в 241:00, и в 242:00, и в 243:00, и в 244:00, и в 245:00, и в 246:00, и в 247:00, и в 248:00, и в 249:00, и в 250:00, и в 251:00, и в 252:00, и в 253:00, и в 254:00, и в 255:00, и в 256:00, и в 257:00, и в 258:00, и в 259:00, и в 260:00, и в 261:00, и в 262:00, и в 263:00, и в 264:00, и в 265:00, и в 266:00, и в 267:00, и в 268:00, и в 269:00, и в 270:00, и в 271:00, и в 272:00, и в 273:00, и в 274:00, и в 275:00, и в 276:00, и в 277:00, и в 278:00, и в 279:00, и в 280:00, и в 281:00, и в 282:00, и в 283:00, и в 284:00, и в 285:00, и в 286:00, и в 287:00, и в 288:00, и в 289:00, и в 290:00, и в 291:00, и в 292:00, и в 293:00, и в 294:00, и в 295:00, и в 296:00, и в 297:00, и в 298:00, и в 299:00, и в 300:00, и в 301:00, и в 302:00, и в 303:00, и в 304:00, и в 305:00, и в 306:00, и в 307:00, и в 308:00, и в 309:00, и в 310:00, и в 311:00, и в 312:00, и в 313:00, и в 314:00, и в 315:00, и в 316:00, и в 317:00, и в 318:00, и в 319:00, и в 320:00, и в 321:00, и в 322:00, и в 323:00, и в 324:00, и в 325:00, и в 326:00, и в 327:00, и в 328:00, и в 329:00, и в 330:00, и в 331:00, и в 332:00, и в 333:00, и в 334:00, и в 335:00, и в 336:00, и в 337:00, и в 338:00, и в 339:00, и в 340:00, и в 341:00, и в 342:00, и в 343:00, и в 344:00, и в 345:00, и в 346:00, и в 347:00, и в 348:00, и в 349:00, и в 350:00, и в 351:00, и в 352:00, и в 353:00, и в 354:00, и в 355:00, и в 356:00, и в 357:00, и в 358:00, и в 359:00, и в 360:00, и в 361:00, и в 362:00, и в 363:00, и в 364:00, и в 365:00, и в 366:00, и в 367:00, и в 368:00, и в 369:00, и в 370:00, и в 371:00, и в 372:00, и в 373:00, и в 374:00, и в 375:00, и в 376:00, и в 377:00, и в 378:00, и в 379:00, и в 380:00, и в 381:00, и в 382:00, и в 383:00, и в 384:00, и в 385:00, и в 386:00, и в 387:00, и в 388:00, и в 389:00, и в 390:00, и в 391:00, и в 392:00, и в 393:00, и в 394:00, и в 395:00, и в 396:00, и в 397:00, и в 398:00, и в 399:00, и в 400:00, и в 401:00, и в 402:00, и в 403:00, и в 404:00, и в 405:00, и в 406:00, и в 407:00, и в 408:00, и в 409:00, и в 410:00, и в 411:00, и в 412:00, и в 413:00, и в




Рисунок 5. Пример иллюстрирует PDF напряжения в интересующем узле в последовательные моменты времени в 24-часовой горизонт работы энергосистемы на сутки вперед.

Для реальных энергосистем с системой SCADA EMS эта система обеспечит информацию о параметрах режима и регулярно обновляться практически в режиме реального времени, поэтому контроль за работой степеней параметров режима осуществляется непрерывно. В Кроме того, при наличии системы SCADA EMS данные, собранные по случайным факторам, будут более удобным и постоянно обновляемым. Когда набор данных случайных факторов больше полная, полученная информация становится более четкой. Это еще одно преимущество при использовании Система SCADA EMS в сочетании с методом PPF.

Основная цель данной статьи – разработать подход к расчету RPF, обеспечивающий определенную приемлемую точность, но это также обеспечивает очень быстрые результаты для достижения желаемых результатов.

применение в режиме практически «реального времени» работы энергосистемы. Как упоминалось выше, метод MCS сталкивается со многими проблемами и даже невозможен при применении к реальным энергосистемам, особенно к крупномасштабным системам с очень короткими сроками эксплуатации. Алгоритм кластеризации, предложенный для решения проблемы PPF в этой статье, прост, легко реализуем и помогает эффективно справиться с плохой масштабируемостью алгоритма К-средних. Таким образом, ADCPPF может дать быстрые результаты с большими данными, которые можно применить для решения проблем PPF для крупномасштабных энергосистем.

Однако, помимо преимуществ и вклада предлагаемого метода в практическое применение, он также имеет ограничение, которое необходимо устранить: предопределение значения k , как в алгоритме К-средних. Кроме того, нерешенными проблемами являются присущие PPF ограничения, которые не охватывают электромагнитные переходные процессы, а также экстремально ненормальные условия эксплуатации. Планирование и эксплуатация энергосистемы также должны быть сосредоточены на наихудших сценариях будущего и аномальных сценариях (например, волнах тепла, зимних штормах и т. д.). Экстремальные погодные явления, усугубляемые изменением климата и глобальным потеплением, создают высокий уровень неопределенности. Следовательно, для интеграции в проблему PPF следует учитывать большее разнообразие типов неопределенности. Системы накопления энергии (например, аккумуляторы, гидроаккумулирующие гидроэлектростанции и схемы подключения электромобилей к сети) могут смягчить неопределенность, связанную с ВИЭ, которая также не рассматривается в этом исследовании. Аппаратное обеспечение является одним из важных факторов, влияющих на анализ PPF, особенно в отношении времени расчета. Будущие исследования также могут быть сосредоточены на обработке алгоритма на высокопроизводительных компьютерах, что позволит решить проблемы, связанные со временем обработки, и позволит больше сосредоточиться на точности модели. Эти ограничения открывают темы для рассмотрения в будущих исследованиях.

5. Выводы

PPF — эффективный инструмент для расчета и анализа энергосистем, а также учета неопределенностей, существующих в системе. Это может помочь оператору системы в оценке безопасности. Среди различных методов PPF MCS дает очень точные результаты, но часто требует очень больших вычислительных затрат. В этой статье основное внимание уделяется решению проблемы сокращения времени вычислений при моделировании Монте-Карло для создания практического инструмента с высокой точностью, который дает быстрые результаты вычислений, которые можно использовать для решения проблем во временном горизонте эксплуатации энергосистемы. Для достижения этой цели мы используем передовую технику кластеризации данных под названием K-means-lite. Разработанный подход ADCPPF тщательно тестируется на модифицированной шинной системе IEEE-300 и показывает хорошие результаты в сокращении времени вычислений.

Вклад авторов: Методика, НТАН, ДДЛ, ВДН, ВКП и ВКХ; программное обеспечение, НТАН и DDL; Все авторы написали и отредактировали рукопись. Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: Исследование финансировалось Министерством образования и обучения Вьетнама в рамках проекта № CT2022.07.DNA.03.

Заявление о доступности данных: данные содержатся в статье.

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Рекомендации

1. Ле, Д.Д.; Бериззи, А.; Бово, К. Вероятностный подход к оценке безопасности энергетических систем с интегрированными ветровыми ресурсами. Обновить. Энергетика 2016, 85, 114–123. [\[Перекрестная ссылка\]](#)
2. Борковска Б. Вероятностный поток нагрузки. IEEE Транс. Мощность приложения. Сист. 1974, ПАС-93, 752–759. [\[Перекрестная ссылка\]](#)
3. Аллан, Р.Н.; Аль-Шакарчи, MRG Вероятностные методы анализа потоков нагрузки переменного тока. Учеб. Инст. Избрать. англ. 1977, 124, 154–160. [\[Перекрестная ссылка\]](#)
4. Чжан П.; Ли, С.Т. Вероятностное вычисление потока нагрузки с использованием метода комбинированных кумулянтов и расширения Грама-Шарлье. IEEE Транс. Система питания 2004, 19, 676–682. [\[Перекрестная ссылка\]](#)
5. Фан, М.; Виттал, В.; Хейдт, GT; Айянар, Р. Вероятностные исследования потоков мощности для систем передачи с фотоэлектрическими элементами Генерация с использованием кумулянтов. IEEE Транс. Система питания 2012, 27, 2251–2261. [\[Перекрестная ссылка\]](#)

6. Ле, Д.Д.; Бериззи, А.; Бово, К.; Чапессони, Э.; Сирио, Д.; Питто, А.; Гросс, Г. Вероятностный подход к оценке безопасности энергосистемы в условиях неопределенности. В материалах о динамике и контроле основной энергосистемы — IX Оптимизация, безопасность и контроль развивающейся энергосистемы (симпозиум IREP 2013 г.), Крит, Греция, 25–30 августа 2013 г.
7. Су, В.Л. Вероятностный расчет потоков нагрузки с использованием метода точечной оценки. IEEE Транс. Система питания 2005, 20, 1843–1851. [\[Перекрестная ссылка\]](#)
8. Мохаммади, М.; Шаегани, А.; Адаминезад, Х. Новый подход к методу точечной оценки для вероятностного потока нагрузки. Межд. Дж. Электр. Власть 2013, 51, 54–60. [\[Перекрестная ссылка\]](#)
9. Лю, Ю.; Гао, С.; Кюи, Х.; Ю, Л. Вероятностный поток нагрузки с учетом корреляций входных переменных после произвольных распределений. Электр. Система питания Рез. 2016, 140, 354–362. [\[Перекрестная ссылка\]](#)
10. Ю, Х.; Чанг, Калифорния; Вонг, К.П.; Ли, Х.В.; Чжан, Дж. Х. Вероятностная оценка потока нагрузки с использованием гибридной выборки в латинском гиперкубе и разложения Холецкого. IEEE Транс. Система питания 2009, 24, 661–667. [\[Перекрестная ссылка\]](#)
11. Цзоу, Б.; Сяо, К. Решение вероятностной задачи оптимального потока мощности с использованием метода квазимонте-карло и девятого порядка Полиномиальное нормальное преобразование. IEEE Транс. Система питания 2014, 29, 300–306. [\[Перекрестная ссылка\]](#)
12. Хаджян, М.; Роузхарт, штат Вашингтон; Зарейпур, Х. Вероятностный поток энергии с помощью моделирования Монте-Карло с выборкой Latin Supercube. IEEE Транс. Система питания 2013, 28, 1550–1559. [\[Перекрестная ссылка\]](#)
13. Лейте да Силва, АМ; Милхоранс де Кастро, А. Оценка риска при вероятностном распределении нагрузки с помощью моделирования Монте-Карло и Метод перекрестной энтропии. IEEE Транс. Система питания 2018, 14, 1193–1202. [\[Перекрестная ссылка\]](#)
14. Карпинелли, Г.; Карамия, П.; Варилоне, П. Метод многолинейного моделирования Монте-Карло для вероятностного распределения нагрузки системы с ветровыми и фотоэлектрическими системами генерации. Обновить. Энергетика 2015, 76, 283–295. [\[Перекрестная ссылка\]](#)
15. Хаг, МТ; Амиян, П.; Гальвани, С.; Вализаде, Н. Вероятностный поток нагрузки с использованием кластеризации оптимизации роя частиц метод. ИЭПП Генерал. Трансм. Распредел. 2018, 12, 780–789. [\[Перекрестная ссылка\]](#)
16. Халгани, М.Р.; Рамезани, М.; Машади, М.Р. Вероятностный поток энергии на основе моделирования Монте-Карло и кластеризации данных для анализа крупномасштабной энергосистемы, включая ветряную электростанцию. В материалах Канзасской конференции по энергетике и энергетике IEEE 2020 г. (КРЕС), Манхэттен, Канзас, США, 13–14 июля 2020 г.
17. Гашиш, М.С.; Хасаниен, НМ; Джи, Х.; Алкухайли, А.; Альхарби, М.; Акмарал, Т.; Турция, РА; Хурадо, Ф.; Бадр, А.О. Моделирование методом Монте-Карло и метод кластеризации для решения вероятностной задачи оптимального потока энергии для гибридных систем возобновляемой энергии. Устойчивое развитие 2023, 15, 783. [\[CrossRef\]](#)
18. Чжан Р.; Чен, З.; Ли, З.; Цзян, Т.; Ли, Х. Двухступенчатая надежная работа интегрированных мультэнергетических микросетей электроэнергии, газа и тепла. учитывая неоднородные неопределенности. Прил. Энергия 2024, 371, 123690. [\[CrossRef\]](#)
19. Цзян Ю.; Рен, З.; Ли, В. Регион эксплуатации интегрированных энергетических систем с обязательными выбросами углерода: концепции и анализ. IEEE Транс. Поддерживать. Энергия 2024, 15, 1194–1209. [\[Перекрестная ссылка\]](#)
20. Ли, З.; Сюй, З.; Ван, П.; Сяо, Г. Восстановление мультэнергетической системы распределения с реконфигурацией объединенной районной сети посредством распределенного стохастического программирования. IEEE Транс. Умные сети 2024, 15, 2667–2680. [\[Перекрестная ссылка\]](#)
21. Мирафтабаде, С.М.; Коломбо, Греция; Лонго, М.; Фойаделли, Ф. К-средние и альтернативные методы кластеризации в современных энергосистемах. IEEE Access 2023, 11, 119596–119633. [\[Перекрестная ссылка\]](#)
22. Олуканми, ПО; Нелвамондо, Ф.; Марвала, Т. k-Means-Lite: Кластеризация больших наборов данных в реальном времени. В материалах 5-й Международной конференции по мягким вычислениям и машинному интеллекту, Найроби, Кения, 21–22 ноября 2018 г.; стр. 54–59.
23. Ван Х.; Чан, HD; Ван, Дж.; Лю, Х.; Ван, Т. Анализ долгосрочной устойчивости энергетических систем с использованием энергии ветра на основе стохастических дифференциальных уравнений: разработка модели и основы. IEEE Транс. Поддерживать. Энергия 2015, 6, 1534–1542. [\[Перекрестная ссылка\]](#)
24. Ле, Д.Д.; Гросс, Г.; Берицци, А. Вероятностное моделирование производства ветровых электростанций на нескольких площадках для приложений на основе сценариев. IEEE Пер. Поддерживать. Энергия 2015, 6, 748–758. [\[Перекрестная ссылка\]](#)
25. Саламе, З.М.; Боровый, Б.С.; Амин, А.А. Согласование фотоэлектрического модуля с местом на основе коэффициента мощности. IEEE Транс. Конверторы энергии. 1995, 10, 326–332. [\[Перекрестная ссылка\]](#)
26. Архив тестовых примеров энергосистемы. Доступно онлайн: http://labs.ece.uw.edu/pstca/pf300/pg_tca300bus.htm. (доступ 6 июнь 2024 г.).

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.



Статья

Схема радара с быстрой обратной синтезированной апертурой

Сочетание съемки с ускорением на графическом процессоре и прыгающего луча и

Алгоритм обратной проекции при широкой полосе пропускания и углах

Цзюньмин Чен¹, Пэнджу Ян^{1,2,*} , Ронг Чжан¹ и Руй Ву^{1,3}¹ Школа физики и электронной информации, Университет Яньань, Яньань 716000, Китай; jmchen@yau.edu.cn (JC); zr2108700733@yau.edu.cn (RZ); wurui@yau.edu.cn (RW)² Ключевая лаборатория информатики электромагнитных волн (МО), Фуданьский университет, Шанхай 200433, Китайский институт³ радиочастотных технологий и программного обеспечения, Пекинский технологический институт, Пекин 100081, Китай

* Переписка: pjiang@fudan.edu.cn

Аннотация: Методы визуализации радаров с обратной синтезированной апертурой (ISAR) часто используются в приложениях классификации и распознавания целей из-за их способности создавать изображения с высоким разрешением для движущихся целей. Чтобы удовлетворить потребности ISAR-изображений в электромагнитных расчетах с высокой эффективностью и точностью, представлен новый метод ускоренных стреляющих и отражающихся лучей (SBR), сочетающий в себе графический процессор (GPU) и древовидную структуру иерархий граничных объемов (BVH). Чтобы преодолеть проблему несфокусированных изображений с помощью процедуры ISAR на основе Фурье в условиях широкого угла и широкой полосы пропускания, разработан эффективный алгоритм параллельной обратной проекции (BP) с использованием метода ускорения графического процессора. Представленный SBR с графическим ускорением проверен в сравнении с методом RL-GO в коммерческом программном обеспечении FEKO v2020. Для изображений ISAR четко указано, что сильные центры рассеяния, а также профили целей могут наблюдаться при больших углах азимута, и широкая полоса пропускания 3 ГГц. Это наблюдения. $\varphi = 90^\circ$ также указывает на то, что изображения ISAR сильно чувствительны к углам наблюдения. Кроме того, можно наблюдать очевидные боковые лепестки из-за искажения фазовой истории электромагнитной волны в результате мультипольного рассеяния. Результаты моделирования подтверждают осуществимость и эффективность нашей схемы за счет объединения SBR с графическим ускорением и алгоритма BP для быстрого моделирования изображений ISAR в условиях широкого угла и широкой полосы пропускания.

Ключевые слова: ISAR-изображения; метод стрельбы и отражения лучей; ускорение графического процессора; дерево BVH; алгоритм обратной проекции



Цитирование: Чен, Дж.; Ян, П.; Чжан, Р.; Ву, Р.

Схема быстрого радиолокационного изображения с обратной синтетической апертурой, сочетающая в себе съемку с ускорением графического процессора, алгоритм отраженных лучей и обратную проекцию в широкой полосе пропускания и под широкими углами. *Электроника* 2024, 13, 3062. <https://doi.org/10.3390/электроника13153062>

Академический редактор: Чиман Кван

Поступила: 4 июня 2024 г.

Пересмотрено: 29 июля 2024 г.

Принято: 30 июля 2024 г.

Опубликовано: 2 августа 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

Радар с обратной синтезированной апертурой (ISAR) представляет собой мощную радиолокационную систему с активной микроволновой визуализацией, широко используемую в военных и гражданских целях благодаря ее способности создавать изображения с высоким разрешением движущихся целей практически в любых погодных и круглосуточных условиях [1–3]. Изображения ISAR можно получить путем фокусировки данных поля рассеяния под разными углами и частотами, которые представляют собой двумерное представление целевого рассеивающего центра [4–6]. Моделирование изображений ISAR для крупных электрических целей занимает чрезвычайно много времени из-за расчета поля рассеяния по множеству углов и частот. Для эффективного расчета рассеяния от электрических крупных целей было разработано несколько методов и их улучшенных версий, а также методы ускорения, включая как низкочастотный численный метод, так и методы высокочастотной аппроксимации [7,8]. Из-за огромных требований к вычислительному времени и памяти, чисто численные методы, такие как метод моментов (MoM) и метод конечных элементов (FEM), сталкиваются с огромными проблемами [9]. Благодаря хорошему компромиссу между точностью и эффективностью методы высокочастотной аппроксимации широко используются при моделировании изображений ISAR для

электрические крупные цели. Среди них наиболее популярным является метод стреляющих и отражающихся лучей (SBR), который представляет собой сочетание физической оптики (ПО) и геометрической оптики (ГО) и подходит для учета многократного рассеяния.

Следуя предложению Линга метода SBR в 1989 году, исследователи внедрили многочисленные усовершенствования [10], такие как метод стрельбы и отражения лучей во временной области (TDSBR), двунаправленную аналитическую трассировку лучей [11] и т. д. Эти достижения имели способствовали росту популярности метода прыгающих лучей. В последние годы предложен метод прыгающих лучей с ускорением на графическом процессоре, основанный на безстековом алгоритме обхода дерева k-мерности (Kd), позволяющий эффективно выполнять процесс трассировки лучей на графическом процессоре [12]. В [13] предложен усовершенствованный метод отраженных лучей с использованием метода движения лучей для ускорения процесса трассировки лучей и повышения эффективности пересечения лучей, что позволяет эффективно рассчитывать характеристики рассеяния электрически больших целей. В [14] включение обратных траекторий лучей в метод SBR предлагается для повышения точности прогнозирования поперечного сечения резонатора (RCS), которое может быть реализовано в существующем коде SBR почти тривиально, одновременно обеспечивая потенциально существенное улучшение точности прогнозирования. Предлагается метод обратной трассировки лучей, основанный на веревочной структуре данных Kd-дерева, которая, как было продемонстрировано, дает удовлетворительные результаты при расчете характеристик высокочастотного рассеяния [15]. Помимо улучшения SBR за счет использования графических процессоров и структур данных, метод SBR также был интегрирован с другими методами электромагнитных вычислений, что сделало этот метод более полным при рассмотрении характеристик электромагнитного рассеяния сложных целевых структур [16–16]. 19]. Например, метод SBR на основе октодерева в сочетании с физической теорией дифракции (PTD) представлен для анализа электромагнитного (ЭМ) рассеяния от движущейся мишени [20]. В [21] предложен гибридный метод эквивалентного дипольного момента (EDM), MOM и SBR для повышения вычислительной эффективности ЭПР сложных объектов в рамках EDM. В этом гибридном методе используется итерационный подход для повышения производительности алгоритма, обеспечивающий высокую точность и сокращающий время вычислений.

На основе моделирования электромагнитного рассеяния сфокусированные ISAR-изображения могут быть получены путем применения алгоритма обработки сигнала, включающего алгоритм дальней доплерографии (RD), алгоритм полярного формата (PFA), алгоритм обратной проекции (BP) и др. [22–24]]. Наиболее часто используемый алгоритм построения изображений ISAR интерполирует полярные данные в декартову сетку, а затем применяет двумерное БПФ для достижения реконструкции ISAR. В частном случае, в условиях малого угла и малой полосы пропускания, изображения ISAR могут быть приблизительно получены путем выполнения обратного преобразования Фурье данных двумерного поля обратного рассеяния, а результирующие изображения ISAR состоят из центров рассеяния цели с их коэффициентом электромагнитного отражения. Благодаря своей пригодности для параллельной обработки графического процессора и возможности формирования изображений ISAR в любом режиме алгоритм BP и его модифицированные версии широко используются в приложениях формирования изображений SAR/ISAR [25]. Еще в 1989 году был предложен упрощенный алгоритм BP и его архитектура параллельной обработки, в которой используется форма радиолокационного сигнала в качестве импульсной характеристики фильтра для получения отфильтрованной проекции [26]. До сих пор алгоритм BP на основе графического процессора все еще разрабатывается для оптимизации пиковой производительности алгоритма BP на серверах и миниатюрных устройствах с графическим процессором, которые могут учитывать различия в аппаратных платформах, а также различия в масштабах данных [27]. В [28] разработан алгоритм построения изображений ISAR для составных сцен «цель-океан», основанный на стреляющих и отражающихся лучах во временной области (TDSBR). В [29] итерационная физическая оптика во временной области (TD-LIPO) предлагается для анализа рассеяния на электрически больших и сложных мишенях. В [30] разработан ускоренный итерационный метод физической оптики во временной области для анализа рассеяния на электрически больших и сложных мишенях и выполнено ОБПФ для получения ISAR-изображения в условиях малой по

В данной статье, направленной на получение изображений ISAR для больших электрических целей в условиях широкой полосы пропускания и широкого угла, данная статья посвящена схеме получения изображений ISAR путем объединения SBR с графическим ускорением на основе графического процессора и ускорения дерева BVH с ускорением BP с помощью графического процессора. алгоритм. Для повышения эффективности пересечения лучей строится древовидная структура BVH.

графическом процессоре. Чтобы повысить эффективность пересечения лучей, древовидная структура BVH строится в соответствии с целевой структурой, которая реализована в C++AMP для достижения параллельного ускорения вычислений на графическом процессоре. Метод SAH включен в разделение во ограничивающего сцены, эффективно смягчая влияние перекрытия ограничивающего прямоугольника на эффективность прохождения лучей древовидной структуры BVH. Эффективно выполнять моделирование изображений ISAR в соответствии с целевой структурой, которая реализована в C++AMP для достижения параллельного использования графического процессора. В результате ускорения вычислений был разработан алгоритм ускоренной визуализации АД на базе графического процессора. Метод SAH встроен в ограничивающую рамку сцены. унифицированная архитектура устройств (CUDA).

Этот документ организован следующим образом: в разделе 2 представлен SBR с ускорением на графическом процессоре, использующий эффективность древовидной структуры BVH. Для эффективного моделирования изображений ISAR в разделе 3 представлены алгоритмы визуализации АД с ускорением на графическом процессоре. В разделе 4 представлены результаты и обсуждение, а также несколько моделей моделирования архитектуры для каждого условия широкой полосы пропускания. Раздел 5 завершает эту статью.

2.1. Расчет многократного рассеяния с использованием PO и GO

2. SBR с ускорением на графическом процессоре с использованием древовидной структуры BVH

В качестве метода высокочастотной аппроксимации используется метод стреляющих и отраженных лучей. 2.1. Расчет многократного рассеяния с использованием PO и GO

представляет собой комбинацию PO и GO, которая использует GO для отслеживания отражения электромагнитных волн. В качестве метода высокочастотной аппроксимации используется метод стреляющих и отражающихся лучей. Траектория PO и PO для расчета поля рассеяния, что дает большое преимущество в SoIvnp, представляет собой комбинацию PO и GO, которая использует GO для отслеживания задач повторного электромагнитного рассеяния электромагнитных волн для сложных целей [31]. В соответствии с траекторией аппроксимации PO и PO для расчета поля рассеяния, что дает большое преимущество в теории мата поверхности мишеней делятся на светлые и темные области в зависимости от решения задач электромагнитного рассеяния сложных мишеней [31]. По данным PO

освещаются поверхности электромагнитными волнами или нет. В суммарном поле, рассеянном по приближенной теории, темная область не должна использоваться. Однако, это предположение справедливо только в том случае, если задуматься о том, освещается ли поверхность электромагнитными волнами или нет. Освещенное

длина волны. Однако это предположение не учитывает геометрии мишени. Его рассеяние из темной области полагается справедливым, когда длина волны электромагнитной волны намного меньше ширины цели. Следовательно, можно определить общее освещение падающей волной, когда размеры цели очень велики; не освещается напрямую падающей волной, когда размеры цели очень велики. перпендикулярно направлению падающей волны. Предполагая, что общее поле равно нулю на тени, большой вдоль перпендикулярного направления падающей волны. Предполагая, что общее поле равно нулю поверхности будет означать разрыв поля на заштрихованной границе. Следовательно, t на заштрихованной поверхности будет означать разрыв поля на заштрихованной границе.

Чтобы устранить разрыв в граничном поле, необходимо добавить линейный интеграл. Поэтому, чтобы устранить разрыв в граничном поле, необходимо добавить линейный интеграл.

границе [32,33]. На рисунке 1 представлена схема многократного рассеяния SBR на образце (желтые стрелки) 1-е отражение (зеленые стрелки), 2-е отражение (зеленые стрелки), в которых только 1-е стрелки изображены.




Рис. 1. Принципиальная схема многократного рассеяния.

Поле PO мишени идеального электрического проводника (ПЭК) в позиции rs можно выразить Поле PO мишени идеального электрического проводника (ПЭП) в позиции sr можно выразить как [34]

нажата как [34]

$$\begin{aligned} \mathcal{E}_s^{\text{po}}(rs) &= jk\eta \int_C \kappa_c \times \kappa_c \times J G(rs, r') dS' \\ &= jk\eta \int_C \frac{Hie jk(rs-r)}{2\pi rs} \kappa_c \times \kappa_c \times n \times h \times e jk(k' i - k' s) \cdot r' dS' \end{aligned} \quad (1)$$

коэффициент () Γ_m DF при Γ_m обычно обозначается как $\frac{D_F D_m}{1 + M + \beta} \cdot K_0 P_{M+1} P_m$, который (представляет собой разность фаз между двумя соседними точками выражения. Подстановка Уравнение (1) в уравнение (4), рассеянное поле x после отражения m -го луча может быть выражается как [37–40]

В уравнении (5) $E_x^{PO}(r_m)$ — поле PO , создаваемое фасетным элементом, на который наносится удар m -й луч, а x — количество пораженных фасетных элементов. Результирующее рассеянное поле для каждого луча впоследствии накладывается для получения общего рассеянного поля.

$$\exists SBR_{\text{всего}} \quad E_x^{PO}(r_m) = \sum_{l=1}^L E_x^{PO}(r_m) \quad (6)$$

В уравнении (6) L — общее количество лучей, а x — это площадь некоторого треугольного элемента лица, в который попало.

2.2. Трассировка лучей с ускорением на графическом процессоре с использованием древовидной структуры BVH 2.2.1. Процесс ускорения графического процессора

В этой статье SBR с ускорением на графическом процессоре распараллеливается с использованием ускоренного массового параллелизма C++ (C++AMP). По сравнению с процессорами графические процессоры обладают большим количеством ядер, что делает их более подходящими для массовой параллельной обработки. C++AMP — это платформа гетерогенных параллельных вычислений на основе C++, выпущенная Microsoft, которая представляет собой собственную модель программирования с преимуществом работы на разных устройствах на платформе Windows [41]. Большинство методов программирования для графических процессоров, таких как Direct Compute и OpenCL, требуют разных языков программирования и компиляторов. C++AMP объединяет язык программирования и компилятор, что отличает его от других подходов. Библиотека C++ AMP обеспечивает параллельные вычисления с помощью набора абстракций и высокоуровневого API, при этом доступ к базовому оборудованию графического процессора осуществляется напрямую через прямые вычисления [42,43]. Важно выделить массив для применения C++AMP для реализации параллельных вычислений. Шаблон массива находится в пространстве имен параллелизма. Он принимает два параметра: один для типа элемента коллекции, а другой для измерения. Размер массива устанавливается в соответствии с типом элементов коллекции в этом методе статьи.

Например, при сборе данных о частоте развертки и определении <массива а (частота)> в этом примере определяется одномерный массив, размер которого равен количеству частот. Массивы играют чрезвычайно важную роль в C++AMP, представляя представление, которое может обращаться к данным на графическом процессоре, и инкапсулируя массивы или векторы C++, которые являются массивами в <accelerator_view>. В C++AMP графический процессор — не единственный ускоритель, и каждый ускоритель имеет собственное представление по умолчанию. После создания массива данные будут перенесены в память графического процессора, где графический процессор сможет получить к ним непосредственный доступ. Функция <parallel_for_each> используется для выполнения задач параллельных вычислений. Функция <parallel_for_each> — это функция параллельного выполнения в C++AMP, которая принимает диапазон индексов и лямбда-функцию и выполняет эту лямбда-функцию параллельно на графическом процессоре для каждого индекса. Функция <parallel_for_each> делегирует задачи параллельных вычислений функциям ядра графического процессора, которые можно напрямую назначить аппаратному обеспечению графического процессора через API Direct Compute.

Ключевое слово <restrict(amp)> используется для указания того, что функция должна выполняться только на графическом процессоре. Он используется для идентификации конкретных блоков кода и лямбда-функций, которые будут выполняться на графическом процессоре, и позволяет компилятору оптимизировать функцию для одной инструкции в нескольких потоках (SIMT) [44]. Операции внутри функции будут использовать инструкции SIMT для достижения эффекта многопоточных параллельных вычислений с одной командой. C++AMP синхронизирует данные и копирует их из памяти графического процессора обратно в память хоста после того, как функция <parallel_for_each> выполнит задачу параллельных вычислений.

На рис. 3 показан процесс параллельных вычислений для C++AMP с использованием API прямых вычислений для отправки параллельных инструкций на устройство графического процессора. Древовидная структура BVH, а также данные лучей и т. д. создаются в ЦП и сохраняются в глобальной памяти графического процессора. Данные будут автоматически скопированы из хоста ЦП в память графического процессора путем создания массива <array_view>, что позволит графическому процессору напрямую обращаться к этим данным. Постоянная память в графическом процессоре будет хранить данные, которые остаются неизменными во время параллельных вычислений. Память текстур используется для хранения данных во время рендеринга модели. В аппаратной архитектуре графического процессора имеется множество потоковых мультипроцессоров (SM), а SM в графических процессорах используют архитектуру SIMT. Каждый SM содержит несколько потоковых процессоров (SP), а каждый SP

использование массива `<array_view>`, что позволяет графическому процессору напрямую обращаться к этим данным. Постоянная `ie` память в графическом процессоре будет хранить данные, которые остаются неизменными во время параллельных вычислений.

Память текстур используется для хранения данных во время рендеринга модели. В аппаратной архитектуре графического процессора имеется множество потоковых мультипроцессоров (SM), а SM в графических процессорах используют архитектуру ^{6 из 24} SIMD. Каждый SM содержит несколько потоковых процессоров (SP), и каждый SP соответствует потоку. Один варп состоит из 32 потоков, причем количество потоков на варп определяется архитектурой графического процессора. Warp — это планирование и выполнение, соответствующее потоку. Одна основа состоит из 32 нитей, число

блоков SM, где потоки в каждой деформации выполняют вычисления параллельно. Количество пре- потоков на варп определяется архитектурой графического процессора. Warp — это планирование и

Как графический процессор SIMD, где потоки в каждой деформации выполняются параллельно и порционно кубу оборады были скарз во да в е с функцией `parallel_for_each` называется задачей ило дреовидной структуры

SM графического процессора, через SIMD можно делить задачи на группы, которые называются структурами деформации. Архитектура SIMD позволяет использовать потоки внутри деформации для выполнения последовательности инструкций, включая обнаружение столкновений, трассировку лучей, PO каждая деформация для выполнения последовательности инструкций, включая обнаружение столкновений, трассировку лучей, расчет поля и другие операции в параллельных режимах. В архитектуре SIMD расчет поля PO и другие операции выполняются в параллельных режимах. В архитектуре SIMD

Графический процессор назначает поток каждому лучу. Древоидная структура BVH получается путем доступа к потоку. Графический процессор назначает поток каждому лучу. Древоидная структура BVH получается путем доступа к потоку. Глобальная память графического процессора и отвечает за расчет пути трассировки лучей и глобальная память графического процессора, а также отвечает за расчет пути трассировки лучей и PO

поле PO. В функции `parallel_for_each` обнаружение пересечения и параллельное поле ускорения. В функции `parallel_for_each` обнаружение пересечения и параллельное ускорение

Создание лучей и ограничение диапазона лучей происходит в древоидной структуре BVH. После прохождения лучей завершение функции `parallel_for_each` завершено, C++ AMP копирует `scat` - выполнение функции `<parallel_for_each>` перед тем, как поле из памяти графического процессора в память хост-машину. По сути, это означает, что для каждой точки, которую вы хотите получить, вы можете получить поле расстояния цели.




Рисунок 3. Процесс параллельных вычислений с помощью API Direct Connect для обработки параллельных данных.

Информация о чипах и их структуре используется для того, чтобы структура BVN-дерева генерировалась в ЦП, как показано на рисунке 4. ЦП будет совместно использовать данные дерева BVN с глобальной памятью графического процессора и будет совместно использовать эти данные с каждым потоком.

BVN-дерево в глобальную память графического процессора, и оно будет делиться этими данными с каждым потоком. В архитектуре SIMT инструкции передаются в варп с помощью Direct Compute API. Архитектура SIMT, инструкции передаются в варп с помощью Direct Compute API.

Потоки в варпе будут выполнять полученные инструкции последовательно и параллельно, а

Потоки в варпе будут выполнять полученные инструкции последовательно и параллельно, а каждый поток в варпе будет отвечать за вычисление одного луча. На этом этапе все


каждый поток в варпе будет отвечать за вычисление одного луча. На этом этапе регистрируются все лучи, пересекающие дерево BVN, пересекающие цель, и их отраженные лучи.

лучи, пересекающие дерево BVN, пересекающие цель, регистрируются, а их отраженные лучи продолжают пересекать структуру. Если луч не пересекает структуру, он удаляется. Лучи, которые достигают цели, сохраняются до тех пор,

отслеживаются до тех пор, пока они не достигнут цели. Затем центральный графический процессор вычисляет рассеянное поле от этих лучей.

Данные всех лучей для определения общего поля рассеяния от цели

чтобы определить общее поле рассеяния от цели.



2.2.2. Алгоритм трассировки лучей с использованием дерева BVH

попадает в corteжи треугольной поверхности.



Рисунок 5. Дрессовидная структура БВН с учетом многократного рассеяния между ионами треугольной поверхности

столкновений. Мы построим ограничивающую рамку, которая окружает цель в соответствии с

с целевыми геометрическими особенностями, а его коробчатая структура представляет собой осесимметричную

ограничительную рамку, ограничительную рамку AABB. В древовидной структуре BVH все кортежи хранятся в t и обнаружении столкновений. Мы построим ограничивающую рамку, охватывающую цель, в соответствии с листовые узлы дерева BVH, а средние узлы хранят информацию о блоке. Наконец, геометрические характеристики объекта и его коробчатая конструкция представляют собой осесимметричную ограничивающую конструкцию. Вся информация о сцене хранится в древовидной структуре BVH [45]. При перемещении t -блока — ограничивающая рамка AABB. В древовидной структуре BVH все кортежи хранятся в листе.

ВУН-дерево, луч сначала определит, пересекается ли он с прямоугольником или нет. Если это не внутренние узлы дерева BVH, то средние узлы хранят информацию о блоке. Наконец, весь

информационный продукт всех кортежей в блоке доступен в t -блоке. Приближенно дерево BVH, луч сначала рассудит, пересекается ли он с коробкой или нет. Если оно не пересекается, то

пропускает блок и не поддерживает его. Если же он пересекается, то кортежи делятся, и все кортежи в блоке будут

двух частей. На рисунке 6 сцена содержит восемь кортежей. На шаге 1 кортежи делятся на две части.

Если лучи света не пересекаются с ограничивающей рамкой, то части сцены. Если световые лучи не пересекаются с ограничивающей рамкой, то они будут не будут пересекаться с кортежами, которые могут исключать половину кортежей за один раз, и не пересекаться с кортежами, которые могут исключать половину кортежей за один раз и, таким образом,

уменьшить количество пересечений. На шаге 2 мы продолжаем делить кортежи на hal , и

и таким образом сложность пересечения лучей может быть уменьшена с $O(n)$ до $O(\log n)$. Таким

образом, сложность пересечения лучей может быть уменьшена с $O(n)$ до $O(\log n)$ [46].

После того как луч пересекся с ограничивающей рамкой, луч продолжает пересекаться с

Уравнение параметра луча можно выразить как

$$r(t) = o + d \cdot t \quad (7)$$




Рисунок 6. Процесс сегментации треугольной сцены.

В уравнении (7) o и d — начальная точка луча и нормированный вектор направления луча, соответственно.

Подставив уравнение параметра луча в неявное уравнение плоскости вектор соответственно. Подставив уравнение параметра луча в неявную плоскость eq — плоскость, в которой расположен кортеж, неявное уравнение плоскости можно записать как

Если рассматривать плоскость, в которой расположен кортеж, неявное уравнение плоскости можно записать в виде

$$n^T (o + d \cdot t) = c \quad (8)$$

Из уравнения (8) параметр t , соответствующий точке пересечения луча

Из уравнения (8) параметр t , соответствующий точке пересечения t с плоскостью, можно определить как

луч с плоскостью можно решить как

$$t = \frac{c - n^T \cdot o}{n^T \cdot d} \quad (9)$$

В данной статье элементом поверхности является треугольный элемент поверхности, а плоскостью

параметрическое уравнение элемента треугольной поверхности:

В данной статье поверхностным элементом является треугольный элемент поверхности, а

метрическое уравнение элемента треугольной поверхности:

$$(f, u, v) = (1 - u - v) \cdot p_0 + u \cdot p_1 + v \cdot p_2 \quad (10)$$

$$(f, u, v) = (1 - u - v) \cdot p_0 + u \cdot p_1 + v \cdot p_2$$

(1

где u и v — координаты центра масс треугольника, удовлетворяющие $u \geq 0$ и $u+v \leq 1$. 9 из 24 0
 Треугольный элемент грани можно рассматривать как отображение единицы, где u и v — координаты центра масс треугольника, удовлетворяющие $u \geq 0$ элементу грани треугольника на трех краях, $v \geq 0$, $u+v \leq 1$. Треугольный элемент грани можно рассматривать как отображение единицы, где u и v — координаты центра масс треугольника, удовлетворяющие $u \geq 0$ элементу грани треугольника на трех краях, $v \geq 0$, $u+v \leq 1$. Треугольный элемент грани можно рассматривать как отображение единичного треугольника (лицевой элемент по трем краям).
 Объединив уравнение (11) с уравнением (7), можно получить (11)

Объединив уравнение (11) с уравнением (7), можно получить $\tau_{\text{Б}}$ (11)

Объединив уравнение (11) с уравнением (7), можно получить (12)

$$[\Pi_{020} \Pi_{120}^M]_{\text{ТМ}}^T = 0 \quad (12)$$

В уравнении (12) М — матрица, преобразующая треугольный элемент грани в единичный (12) элемент грани в плоскости u, v, в котором отображаемый луч ортогонален. В уравнении (12) М — матрица, преобразующая треугольный элемент грани в единичный треугольный элемент грани. Отображение элементов треугольной поверхности в u,v

В уравнении (12) M⁻¹ — это матрица, преобразующая треугольный элемент грани в единицу измерения, единственный треугольный элемент грани в плоскости u,v, в котором отображаемый луч ортогонален плоскости, показан на рисунке 7. Рисунок 7а представляет собой случай до отображения, а рисунок 7б — представляет собой треугольный элемент грани в плоскости u,v для случая до отображения; и рисунок 7в — представляет собой единичный треугольный элемент грани. Отображение элементов треугольной поверхности в u,v

Треугольным элементом грани. Отображение элементов треугольной поверхности в плоскость u


Плоскость показана на рисунке 7. Рисунок 7а представляет собой случай до отображения, а рисунок 7б — показывает на рисунке 7. Рисунок 7в — представляет собой случай до сопоставления, а рисунок 7б — случаи

случай соответствует уравнению (11). На рисунке 7с показано пересечение луча с соответствующим уравнением (11). На рисунке 7г показано пересечение луча с

единичный элемент треугольной поверхности после отображения.

единичный элемент треугольной поверхности после отображения.

- M⁻¹p₀



() а Рис. 7. Отображение элементов треугольной поверхности в плоскость u, v . а) случай до картирования; б) Случай, соответствующий уравнению (11); в) Пересечение луча с единичным треугольником Рис. 7. Отображение элементов треугольной поверхности в плоскость u, v . а) случай до картирования; элемент поверхности после отображения.

(b) Случай, соответствующий варианту (1) (b) (4) Пареллельным лучам, идущим из точки источника, элемент поверхности после отображения в соответствии с методом половинного деления ограничивающие рамки в сцене могут перекрываться или пересекаться, а перекрытие ограничивающих рамок показано на рисунке 8. На рисунке 8 согласно методу половинного деления ограничивающие рамки в сцене могут перекрывать или пересекаться, а перекрытие ограничивающих рамок показано на рисунке 8. На рисунке 8 или пересекаться, а перекрытие ограничивающих рамок показано на рисунке 8. На рисунке 8 необходимо передать обе ограничивающие рамки, что приводит к снижению эффективности пересечения светового луча с объектами сцены, что приводит к снижению эффективности пересечения. Когда свет перескает дерево BVH, перекрытие ограничивающих рамок приведет к тому, что свет перескает обе ограничивающие рамки, что приводит к снижению эффективности пересечения.




Рисунок 8. Падающая волна

Рисунок 8. Дипграмма, позволяющая избежать появления нежелательных вершин, в процессе построения дерева BVH

Чтобы устранить явление перекрытия блоков конвертов, в процессе построения дерева BVH вместо метода половинного деления применяется метод деления SAH. SAH основан на эвристическом методе деления площади поверхности, и после добавления SAH мы можем оценить вероятность попадания светового луча в огибающие блоки с точки зрения размера площади поверхности родительского огибающего блока, в котором есть два или больше перекрывающихся дочерних обволакивающих коробок.

В древовидной структуре BVH в предположении, что текущий узел имеет три ограничивающие рамки A, B и C, стоимость пересечения луча с текущим узлом равна

$$c(A, B, C) = p(A) \sum_{i \in A} t(i) + p(B) \sum_{j \in B} t(j) + p(C) \sum_{k \in C} t(k) + t_{trav} \quad (13)$$

В уравнении (13) $t(i)$ — это стоимость пересечения каждого подкорпуса, а $t(i)$ — i -й кортеж в дочернем корпусе. $p(A)$, $p(B)$ и $p(C)$ — вероятности попадания света на объекты в ограничивающих прямоугольниках A, B и C соответственно. t_{trav} — стоимость света, проходящего через дерево BVH.

В SAH мы используем площадь поверхности дочернего ограничивающего прямоугольника в родительском узле вместо вероятности попадания луча в ограничивающий прямоугольник. Предполагая, что площади поверхности дочерних ограничивающих рамок A, B и C равны $S(A)$, $S(B)$ и $S(C)$ соответственно, а поверхность ограничивающей рамки D родительского узла равна $S(D)$, Уравнение (13) можно переписать в виде

$$c(A, B, C) = \frac{S(A)}{S(D)} \sum_{i \in A} t(i) + \frac{S(B)}{S(D)} \sum_{j \in B} t(j) + \frac{S(C)}{S(D)} \sum_{k \in C} t(k) + t_{trav} \quad (14)$$

После решения оптимального метода деления путем вычисления минимального значения уравнения (14) лучевой обход дерева BVH становится наиболее эффективным [47].

3. Алгоритм визуализации АД с графическим ускорением

3.1. Алгоритм BP для формирования

изображений ISAR. В условиях малого угла и малой полосы пропускания изображения ISAR могут быть приблизительно получены путем выполнения обратного преобразования Фурье данных двумерного поля обратного рассеяния, а результирующие изображения ISAR состоят из центров рассеяния цели с их коэффициент электромагнитного отражения. Благодаря своей пригодности для параллельной обработки графического процессора и способности формирования изображений ISAR в любом режиме алгоритм BP и его модифицированные версии широко используются в приложениях формирования изображений SAR/ISAR. Алгоритм визуализации АД представляет собой метод с высокой точностью визуализации. Однако из-за своей высокой сложности алгоритм BP не так хорош, как другие алгоритмы визуализации, с точки зрения скорости визуализации. В этой статье, направленной на получение изображений ISAR для электрических крупных целей в условиях широкой полосы пропускания и широкого угла, в этой статье разработан алгоритм ускоренного изображения BP на базе графического процессора с помощью CUDA, сохраняющий при этом точность изображения алгоритма BP.

Фундаментальная идея алгоритма BP заключается в когерентном наложении рассчитанных эхо-сигналов каждого импульса путем передачи электромагнитных импульсов и расчета двусторонней временной задержки между точками пикселей в области изображения и радаром в момент каждого импульса. Наложение зависит от фазового соотношения между точками пикселей. Если эхо-сигналы синфазны, эхо-сигналы наложенных точек пикселей становятся все более сильными. При наложении точек пикселей с разными фазами эффект слабее. В качестве точного алгоритма во временной области профиль дальности в алгоритме BP получается с использованием метода сжатия импульсов, аналогичного алгоритму Range-Doppler.

Обработка азимутального направления достигается за счет вычисления эхо-сигналов точек пикселей для когерентной суперпозиции, которая связана с углом поворота цели относительно радара. Наблюдается увеличение азимутального разрешения по мере увеличения угла между целью и радаром без видимого ограничения. Для любой траектории движения цели, если траекторию движения можно предсказать заранее, алгоритм BP может обеспечить точную визуализацию.

это сетка для построения изображения. Принципиальная схема обработки проекции для построения изображений ISAR. Область изображения разделена на сетки $N \times N$. (X_a, Y_a) и (X_b, Y_b) — положения цели в сетке изображения в момент времени a и b соответственно. V — скорость и направление движущейся цели. Передающим знаком являются положения цели в сетке изображения в момент времени a и b соответственно. v это скорость и направление движущейся цели. Передающий сигнал [48]

$$s(t, m) = \text{прямоугольный} \left(\frac{t}{T_p} \right) \exp(j2\pi f_0 t + jK t^2) \quad (15)$$




Рисунок 8. Принципиальная схема обработки проекции для построения изображений ISAR.

В уравнении (15) T_p — ширина импульса сигнала, f_0 — несущая частота сигнала, K — частота модуляции. B — полоса пропускания сигнала. Полученное эхо выглядит следующим образом

$$s_r(t, m) = \text{прямоугольный} \left(\frac{t}{T_p} \right) \exp(j2\pi f_0 t + jK t^2) \quad (16)$$

В уравнении (16) $t_{i,j}(m)$ — это двусторонняя задержка от пикселя (X_i, Y_i) в плоскости изображения до радара в медленное время m . $x(m)$, $y(m)$ и $z(m)$ — координаты пикселя (X_i, Y_i) в сетке изображения в пространственной системе координат.

Соответствующий фильтр выглядит следующим образом

лежать от пикселя (X_i, Y_i) в плоскости изображения до радара в медленное время m . $x(m)$, $y(m)$ и $z(m)$ — положения пикселя (X_i, Y_i) в сетке изображения в пространстве $h(t, m) = \exp(j2\pi f_0 t + jK t^2)$ (17)

целевая система координат. Соответствующий фильтр выглядит следующим образом

В уравнении (17) t_0 — двусторонняя задержка на ближайшем расстоянии между целью и радаром. Преобразование свертки во временной области в умножение в частотной области (18)

обработки выход согласованного фильтра может быть выражен следующим образом: В уравнении (17) t — двусторонняя задержка на ближайшем расстоянии между целью и радаром.

Преобразуя свертку во временной области в обработку умножения в частотной области, выходной сигнал согласованного фильтра может быть выражен следующим образом (18)

Высокое разрешение по азимуту достигается за счет когерентного накопления импульсов. Интегральная формула когерентного накопления имеет следующий вид [49] (18)

Высокое разрешение по азимуту достигается за счет когерентного накопления импульсов. Интегральная формула когерентного накопления имеет следующий вид [49] (19)

Энергия каждой точки пикселя в сетке когерентно накладывается на целевое время движения. Значение пикселя накапливается по каждой точке пикселя в течение времени движения для синтеза конечного изображения.

3.2. Ускорение алгоритма BP для обработки изображений ISAR с

помощью графического процессора. CUDA, выпущенная NVIDIA в 2006 году, представляет собой универсальную платформу параллельных вычислений и модель программирования, построенную на графических процессорах. Вычисления для сложных задач можно выполнять более эффективно с помощью программирования CUDA. В последние годы методы программирования CUDA были разработаны как в аппаратном, так и в программном обеспечении [50]. На момент своего первого выпуска CUDA могла использовать графические процессоры с ограниченным количеством ядер, обычно в диапазоне от нескольких десятков до нескольких сотен. Следовательно, было невозможно провести значимое сравнение вычислительной мощности между этими ранними графическими процессорами и графическими процессорами, доступными сегодня [51]. Например, NVIDIA RTX 2080 от NVIDIA, выпущенная 20 сентября 2018 года, представляет собой графический процессор с 2944 ядрами CUDA и вычислительной мощностью FP32 10,07 триллионов раз в секунду. Однако NVIDIA RTX 4090 теперь имеет 16 384 ядра CUDA, а вычислительная мощность FP32 достигает 82,58 триллиона раз в секунду. В последние годы CUDA широко использовала свои мощные возможности параллельных вычислений в области научных вычислений [52].

В этой статье мы реализовали высокопараллельный алгоритм визуализации BP с помощью CUDA. Данные рассеянного поля, полученные в результате расчета SBR, сначала загружаются в глобальную память графического процессора из памяти хоста с помощью функции `<cudaMemcpy>`. Эти данные содержат такую информацию, как азимут, угол падения, частота, точки выборки частоты, точки выборки угла, режим поляризации и т. д. Указанное пространство памяти выделяется для этих параметров из графического процессора с размером памяти $N_f \times N_{phi} \times N_{ft}$ по Функция `<cudaMalloc>`. Глобальные переменные на устройстве определяются с помощью символа `_device_`, включая сигнал сжатия расстояния и переменные, используемые для хранения необработанных данных рассеянного поля, переменные, используемые для хранения координат и положения радара, а также переменные, используемые для хранения окончательных результатов изображения. Сжатие импульсов диапазона необработанных эхосигналов выполняется с использованием библиотеки функций `<cuFFT>` в CUDA, с помощью которой можно реализовать высокопараллельные БПФ и ОБПФ. Сигнал сжатия диапазона копируется в память графического процессора с помощью функции `<cudaMemcpy>` с выделенным размером памяти $N_f \times N_{phi} \times N_{ft}$.

Параллельные ускоренные вычисления в основном реализуются на устройстве с помощью функции ядра CUDA. Ядро — важная концепция в CUDA и функция, которая выполняется параллельно в потоке на устройстве. Функция ядра объявляется с помощью символа `<_global_>`, и количество потоков, необходимое для вызова этой функции, необходимо указать, в частности, с помощью `<<grid, block>>`. Функция ядра выполняется каждым потоком. Процесс азимутальной фокусировки алгоритма BP записывается как функция ядра, и соответствующему количеству потоков выделяется функция ядра, чтобы обеспечить возможность параллельных вычислений на графическом процессоре.

На рисунке 10 функция ядра отвечает за расчет расстояний всех пикселей от радара в каждый азимутальный момент, а также фазовую компенсацию. Положение соответствующего азимутального сигнала определяется расстоянием точки пикселя от радара. Изображение ISAR с использованием алгоритма BP получается путем когерентного наложения эхо-сигналов всех точек пикселей в каждый азимутальный момент. Блоки и потоки определяются как одномерные при запуске функции CUDA алгоритма BP. Распределение потоков в каждом блоке равно N_y , 1, 1 при общем количестве блоков N_x и $(N_x, 1, 1)$ распределении блоков. N_x и N_y — количество пикселей в направлении x и количество пикселей в направлении y соответственно. Чтобы оптимизировать эффективность функции ядра при обработке крупномасштабных данных, вычислительные задачи для пикселей изображения размером более 500×500 выполняются пакетно. Максимальное количество точек пикселей, вычисляемых в каждом пакете, составляет 500×500 , чтобы адаптироваться к ограничениям ресурсов графического процессора. В функции ядра графический процессор выделяет 250 000 потоков для каждого пакета вычислительных задач, причем каждые 500 потоков представляют собой блок, что в общей сложности составляет 500 блоков. Каждый поток отвечает за вычисление значения однопиксельной точки, и несколько пакетов данных будут выполняться

количество точек пикселей, вычисляемых в каждом пакете, составляет 500×500 , чтобы адаптироваться к ограничениям ресурсов графического процессора. В функции ядра графический процессор выделяет 250 000 потоков для каждого пакета вычислительных задач, причем каждые 500 потоков представляют собой блок, что в общей сложности составляет 500 блоков. Каждый поток отвечает за вычисление значения ^{13 из 24} однопиксельной точки, и несколько пакетов данных будут выполняться параллельно в ядре CUDA.




Рисунок 10. Процесс параллельного расчета алгоритма BP для визуализации ISAR с использованием ускорения CUDA.

На рисунке 10 данные разбросанных полей сначала копируются из памяти хоста в графический процессор.

Память — это постоянная лампа, используемая для трансляции инструкций, отправленных хостом. Текстура Глобальная память. Каждый поток может получить доступ к данным, хранящимся в глобальной памяти. Постоянная Память — это постоянная память, используемая для трансляции инструкций, отправленных хостом. Текстурируйте количество пикселей N_x в направлении x и количество пикселей N_y в направлении y , Память используется для хранения данных текстуры. Количество блоков и потоков определяется соответственно. В блоке все потоки выполняют одни и те же инструкции, и каждый поток выполняет количество пикселей N_x в направлении x и количество пикселей N_y в направлении y - функция ядра. Функция ядра использует потоки для реализации высокопараллельной работы.

реакция слияния элементарных функций в узлы, выполняют одни и те же инструкции, и каждый поток выполняет все функции, выполняемые другими потоками. Функции, выполняемые в узлах, являются функциями с фиксированным числом входов. 11

параллелизм, обеспечиваемый работой на разноразмерной сетке пикселей, размером $N_f \times N_{phi}$. Если количество пиксельных сеток в области изображения меньше 500×500 , то соответствующий блок рисунка 11 представляется блок-схема алгоритма ВР с ускорением на графическом процессоре. После выделения области изображения выделяется количество потоков, ответственных за вычисление эхо-данных этого блока. Сетки и накопление их в соответствующие позиции. Сочетание этих количество пиксельных сеток в области изображения меньше 500×500 , тогда соответствующая пиксельная сетка разбивается на несколько подобластей для параллельной обработки, если пикселей больше. Выделяется количество потоков, отвечающих за вычисление эхо-данных этих 500×500 . Каждый блок графического процессора отвечает за обработку одной пиксельной точки, включая пиксельные сетки и накопление их в соответствующие позиции. Комбинация расчета расстояния, фазовой компенсации и т. д. Он вычисляет текущее местоположение пикселя и эти пиксельные сетки, а также текущие пиксели, подлежащие завершению обработки, если пиксели накапливают больше 500. Данные каждого блока графического процессора передаются в соответствующую позицию в конечном изображении. Наконец, выводятся все изображения. Наконец, выводятся все изображения.




Рисунок 11. Блок-схема алгоритма SBR с ускорением на графическом процессоре.

4. Результаты обсуждения.

4.1. Валидация метода SBR с графическим ускорением

Реализация метода электромагнитных вычислений с GPU-ускорением
Реализация метода электромагнитных вычислений с ускорением на графическом процессоре и метода визуализации АД с ускорением на графическом процессоре была представлена ранее, как описано. и метод визуализации АД с ускорением на графическом процессоре был представлен ранее, как описано в этой статье. В этом разделе рассматривается достоверность SBR с ускорением на графическом процессоре, сочетающая GO с PO. В этой статье. В этом разделе достоверность SBR с ускорением на графическом процессоре, сочетающая GO и PO-аппроксимации, проверяется путем сравнения с RL-GO в программном обеспечении FEKO v2020. принимая аппроксимации проверяются сравнением с RL-GO в программе FEKO v2020. На примере полномасштабного истребителя F-22 RL-GO настроен на два типа плотности лучей: Например, полномасштабный истребитель F-22, RL-GO настроен с двумя типами плотности лучей: один - $\lambda/10$, а другой - $\lambda/100$. Сравнение ЭПР дальней зоны производится с электро- $\lambda/10$ и другим $\lambda/100$. Проведено сравнение ЭПР дальней зоны с частотой электромагнитной волны $f_0 = 3$ ГГц. В результате рассеяния модели было получено 2444 треугольных частота электромагнитной волны 3 ГГц. В результате рассеяния модели было получено 2444 треугольных сетки, а дерево BVN было построено для создания 4887 конечных узлов. Модель САПР сетки показана на рисунке 12. Время расчета и стоимость памяти указаны в таблице 1. Процессор нашего компьютера — Intel(R) Core(TM) i5-12490F 12-го поколения с тестовой частотой 3,00 ГГц. Графический процессор представляет собой специальную серию процессоров, произведенную корпорацией Intel для Китая. Графический процессор представляет собой специальную серию процессоров, произведенную корпорацией Intel для Китая. Графический процессор представляет NVIDIA GeForce RTX 2080 с 8,0 Гб выделенной памяти графического процессора, произведенная корпорацией Корпорация NVIDIA в материковом Китае.



с лучевой плотностью учета.





Рис. 13. Угловое распределение ЭПР полномасштабного истребителя F-22: (а) угол падения $\varphi = \theta = 90^\circ$, азимут

ФЕКО. На рисунках 13а,б видно, что RCS, рассчитанная с помощью нашей программы с ускорением на графическом процессоре.

	X 710	X 710	X 7100	X 710	X 710
4.2. Моделирование изображений ISAR					
Рисунок 13а ВВ 207,96 186,4 557,6 181,4			2303,3		130,9
4.2. Моделирование изображений ISAR					
Рисунок 13б (100%) представленные результаты визуализации 15-м типичной авиационной цели.			15,4		30,4

В обсужден. Матрица поля обратного рассеяния репрезентативных авиационных целей имеет вид

нашего метода SBR с ускорением на графическом процессоре, разработанного в этой статье. Для

и обсужден. Матрица поля обратного рассеяния репрезентативных авиационных целей равна 4.2.

Моделирование изображений ISAR

Изображения ISAR с использованием алгоритма BP с ускорением на графическом процессоре, разработанного в этой статье. Для

рассчитывается с помощью нашего метода SBR с ускорением на графическом процессоре, а затем эхо-сигналы фокусируются

В этом разделе представлены и обсуждаются результаты визуализации ISAR типичной авиационной цели.

для получения изображений ISAR с использованием алгоритма BP с ускорением на графическом процессоре, разработанного

Матрица поля обратного рассеяния репрезентативных авиационных целей рассчитывается с помощью нашего

в этой статье. Для сравнения, наш алгоритм BP с ускорением на графическом процессоре также был применен для фокусировки

метода SBR с ускорением на графическом процессоре, а затем эхо-сигналы фокусируются для получения

изображений ISAR с использованием алгоритма BP с ускорением на графическом процессоре, разработанного в этой статье. Для сравнения: наш алгоритм BP с ускорением на графическом процессоре также был использован для

RL-GO даже под определенными углами. Например, на рисунках 16а,d разница в рассеянии в моторной части самолета видна более очевидной, а различия в рассеянии в моторной части самолета более заметны. очевидно на рисунках 16с,ф; На рисунке 16f сильнейше

загромождена такая информация, как конструктивные особенности самолета, а результаты на рисунке 16f не так хороши, как сравнение . Наш алгоритм BP с ускорением на графическом процессоре также был применен для фокусировки обратного рассеяния, результаты рисунка 16с. Когда плотность лучей равна, выходные файлы могут записывать поле, используя метод RL-GO в программном обеспечении FEKO v2020 для получения сфокусированного ISAR.

На рис. 14 показана САД-модель масштабированной модели самолета A380 с размерами. Этот результат визуализации по сравнению с рисунками 16а-с и рисунками 16d-f, что подтверждает, что эффективная модель имеет 3770 треугольников. На рисунках 15а-в показаны три типичные конфигурации наблюдения. Анализ алгоритмов визуализации АД с GPU-ускорением в данной статье со стороны. Таблица с различными диапазонами азимутального сканирования. Угол падения фиксирован и составляет $\theta = 60^\circ$.

показано сравнение времени вычислений и пиковой памяти для рисунка 16.

Параметры изображения ISAR для рисунков 16 и 18 установлены, как указано в таблице 2.




Рисунок 14. Модель автоматизированного проектирования (САПР) и размеры масштабной модели самолета A380.




Рисунок 15. Три типичные конфигурации наблюдения с разными углами азимута при фиксированном наклоне Рис. 15. угол падения $\theta = 60^\circ$. (a) $\phi = 45^\circ$ 135 $\phi = 45^\circ$; (b) $\phi = 45^\circ$ 45 $\phi = 135^\circ$; (c) $\phi = 45^\circ$ 135 $\phi = 45^\circ$.

Таблица 2. Параметры моделирования ISAR для рисунков 16 и 18.

Параметр		Ценить
Матрица	f_0	1,75 ГГц
	B	3 ГГц
	ϕ	90
	θ	60 или 120
Длина волны (м)	x	0,05 м
	y	0,05 м
(a) Точки отбора проб поляризации		200
		ВВ
(б)		(c)
(г)		(е)
		(е)

На рисунке 16 представлены результаты визуализации ISAR для трех типичных конфигураций наблюдения с разными диапазонами азимутального сканирования. Угол падения фиксирован и составляет $\theta = 60^\circ$. Наш Алгоритм визуализации АД с ускорением на графическом процессоре применяется для фокусировки полей обратного рассеяния на получить сфокусированные изображения ISAR. На рисунках 16, рисунках 16d-f показаны RL-GO при плотности лучей $\lambda/10$. без дифракции, а на рис. 16g-i показаны RL-GO при плотности лучей $\lambda/100$ с дифракцией. Сравнивая рисунки 16а-с и 16d-f, можно обнаружить, что результаты метода этой статьи и метод RL-GO лучше согласуются с результатами, полученными с помощью RL-GO компании FEKO.

Палющая волна

метод при условии одинаковой плотности лучей, и он даже превосходит RL-GO при конкретных углах. Например, на рисунке 16а, разница в рассеянии в двигателе часть самолета видна более очевидной, а различия в рассеянии в область двигателя самолета более наглядно видна на рисунках 16с, f; Рисунок 16f имеет сильный беспорядок, который перегружает информацию, например, о структурных особенностях самолет, и результаты рисунка 16f не так хороши, как результаты рисунка 16с. Когда плотность лучей $\lambda/100$, это способно фиксировать геометрические структурные особенности самолет в деталях, поэтому на рис. 16g-i получены очень хорошие результаты визуализации по сравнению с рисунками.

(а) самолет в деталях, поэтому на рис. 16а-г получены очень хорошие результаты визуализации по сравнению с рисунками. Рис. 16а-с и 16д-г, что подтверждает эффективность визуализации АД с графическим ускорением. Рис. 15. Три типичные конфигурации наблюдения с разными азимутальными углами при фиксированных алгоритмах img в данной статье, вид сбоку. В таблице 3 показано время вычислений и пик. угол плотности $\theta = 60^\circ$. (а) $\varphi = 45 \sim 135$; (б) $\varphi = 45 \sim 45$; (в) сравнение памяти для $\varphi = 135 \sim 45$. рисунка 16.




Рисунок 16. Результаты визуализации ISAR с использованием алгоритма визуализации АД с графическим контролем при фиксированном угле падения.

угла $\theta = 60^\circ$. На рисунке 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92, 93, 94, 95, 96, 97, 98, 99, 100, 101, 102, 103, 104, 105, 106, 107, 108, 109, 110, 111, 112, 113, 114, 115, 116, 117, 118, 119, 120, 121, 122, 123, 124, 125, 126, 127, 128, 129, 130, 131, 132, 133, 134, 135, 136, 137, 138, 139, 140, 141, 142, 143, 144, 145, 146, 147, 148, 149, 150, 151, 152, 153, 154, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165, 166, 167, 168, 169, 170, 171, 172, 173, 174, 175, 176, 177, 178, 179, 180, 181, 182, 183, 184, 185, 186, 187, 188, 189, 190, 191, 192, 193, 194, 195, 196, 197, 198, 199, 200, 201, 202, 203, 204, 205, 206, 207, 208, 209, 210, 211, 212, 213, 214, 215, 216, 217, 218, 219, 220, 221, 222, 223, 224, 225, 226, 227, 228, 229, 230, 231, 232, 233, 234, 235, 236, 237, 238, 239, 240, 241, 242, 243, 244, 245, 246, 247, 248, 249, 250, 251, 252, 253, 254, 255, 256, 257, 258, 259, 260, 261, 262, 263, 264, 265, 266, 267, 268, 269, 270, 271, 272, 273, 274, 275, 276, 277, 278, 279, 280, 281, 282, 283, 284, 285, 286, 287, 288, 289, 290, 291, 292, 293, 294, 295, 296, 297, 298, 299, 300, 301, 302, 303, 304, 305, 306, 307, 308, 309, 310, 311, 312, 313, 314, 315, 316, 317, 318, 319, 320, 321, 322, 323, 324, 325, 326, 327, 328, 329, 330, 331, 332, 333, 334, 335, 336, 337, 338, 339, 340, 341, 342, 343, 344, 345, 346, 347, 348, 349, 350, 351, 352, 353, 354, 355, 356, 357, 358, 359, 360, 361, 362, 363, 364, 365, 366, 367, 368, 369, 370, 371, 372, 373, 374, 375, 376, 377, 378, 379, 380, 381, 382, 383, 384, 385, 386, 387, 388, 389, 390, 391, 392, 393, 394, 395, 396, 397, 398, 399, 400, 401, 402, 403, 404, 405, 406, 407, 408, 409, 410, 411, 412, 413, 414, 415, 416, 417, 418, 419, 420, 421, 422, 423, 424, 425, 426, 427, 428, 429, 430, 431, 432, 433, 434, 435, 436, 437, 438, 439, 440, 441, 442, 443, 444, 445, 446, 447, 448, 449, 450, 451, 452, 453, 454, 455, 456, 457, 458, 459, 460, 461, 462, 463, 464, 465, 466, 467, 468, 469, 470, 471, 472, 473, 474, 475, 476, 477, 478, 479, 480, 481, 482, 483, 484, 485, 486, 487, 488, 489, 490, 491, 492, 493, 494, 495, 496, 497, 498, 499, 500, 501, 502, 503, 504, 505, 506, 507, 508, 509, 510, 511, 512, 513, 514, 515, 516, 517, 518, 519, 520, 521, 522, 523, 524, 525, 526, 527, 528, 529, 530, 531, 532, 533, 534, 535, 536, 537, 538, 539, 540, 541, 542, 543, 544, 545, 546, 547, 548, 549, 550, 551, 552, 553, 554, 555, 556, 557, 558, 559, 560, 561, 562, 563, 564, 565, 566, 567, 568, 569, 570, 571, 572, 573, 574, 575, 576, 577, 578, 579, 580, 581, 582, 583, 584, 585, 586, 587, 588, 589, 590, 591, 592, 593, 594, 595, 596, 597, 598, 599, 600, 601, 602, 603, 604, 605, 606, 607, 608, 609, 610, 611, 612, 613, 614, 615, 616, 617, 618, 619, 620, 621, 622, 623, 624, 625, 626, 627, 628, 629, 630, 631, 632, 633, 634, 635, 636, 637, 638, 639, 640, 641, 642, 643, 644, 645, 646, 647, 648, 649, 650, 651, 652, 653, 654, 655, 656, 657, 658, 659, 660, 661, 662, 663, 664, 665, 666, 667, 668, 669, 670, 671, 672, 673, 674, 675, 676, 677, 678, 679, 680, 681, 682, 683, 684, 685, 686, 687, 688, 689, 690, 691, 692, 693, 694, 695, 696, 697, 698, 699, 700, 701, 702, 703, 704, 705, 706, 707, 708, 709, 710, 711, 712, 713, 714, 715, 716, 717, 718, 719, 720, 721, 722, 723, 724, 725, 726, 727, 728, 729, 730, 731, 732, 733, 734, 735, 736, 737, 738, 739, 740, 741, 742, 743, 744, 745, 746, 747, 748, 749, 750, 751, 752, 753, 754, 755, 756, 757, 758, 759, 760, 761, 762, 763, 764, 765, 766, 767, 768, 769, 770, 771, 772, 773, 774, 775, 776, 777, 778, 779, 780, 781, 782, 783, 784, 785, 786, 787, 788, 789, 790, 791, 792, 793, 794, 795, 796, 797, 798, 799, 800, 801, 802, 803, 804, 805, 806, 807, 808, 809, 810, 811, 812, 813, 814, 815, 816, 817, 818, 819, 820, 821, 822, 823, 824, 825, 826, 827, 828, 829, 830, 831, 832, 833, 834, 835, 836, 837,

Таблица 3. Время вычислений и пиковая нагрузка памяти для рисунка 16.

	СБР		РЛТО	
	Время (с)	Память (МБ)	Время (с)	Память (МБ)
Рисунок 16а,г	2233,376,4	2233,376,4	1584,2	177,877,8
Рисунок 16б,д	2623,372,5	2623,372,5	1614,3	179,879,6
Рисунок 16в,е Рисунок 16в,е			1474,1	179,5

Можно заключить, что при одинаковой плотности лучей результаты метода данной работы хорошо согласуются с результатами RL-GO. Далее мы проанализируем разницу между результатами двух методов, когда плотности лучей неодинаковы. На рисунке 16а сильные эхосигналы исходят как от двигателя, так и от части крыла, прикрепленной к двигателю. Область, обозначенная красной стрелкой на (а), обозначает положение крыла. При углах наблюдения луч отразится один раз после удара о крыло. Можно сделать вывод, что при одинаковой плотности лучей 45°135° метода в

частично ниже, и далее базовый уровень разницы между результатами двух методов остается в пределах 10%. Векским ускорением (рис. 16а) мы получили рассеянные эхосигналы, как будто траектории лучей, параллельной максимизации, число падает в три. Этот эффект обозначен красной стрелкой на (а), он представляет положение крыла. луч отразится один раз после попадания в 1. Из-за плоскостности этой части конструкции луч будет в последствии покинуть цель после отражения. В нашем методе SBR с ускорением на графическом процессоре на рисунке 16a,b,g,h. На рис. 16a,b представлены результаты, рассчитанные по методу настоящей работы, многократное рассеяние учтено методом трассировки лучей, при котором максимальное отражение, на рис. 16g,z представлено дифракцией, рассчитанной методом РЛ-ГО, дифракцией при числе плотности лучей 10, /100 в FEKO. И SBR с графическим ускорением, RL-GO в FEKO основаны на лучах, что приводит к явной метод двустороннего рассеяния, связанного с механизмом рассеяния электромагнитных волн. Рис. 16a,b,g,h. На рис. 16a,b показаны результаты, рассчитанные по методу данной работы, а сетевые волны и механизм трассировки лучей. На рис. 16g,z представлены результаты, рассчитанные методом РЛ-ГО с целью и на рисунке 16i. λ/100 в FEKO. И SBR с графическим ускорением, и RL-GO в FEKO — это методы, основанные на лучах. Сравнение результатов изображения ISAR на рисунках 16a-c с рисунками 16d-f и рисунками. Эти пятна рассеяния связаны с механизмом рассеяния электромагнитных волн. 16g-i демонстрирует осуществимость и эффективность нашей схемы за счет объединения GPU-ускорения и механизма трассировки лучей. Из-за пренебрежения дифракционным полем, возникающим из-за SBR с алгоритмом РЛ, это приводит к искажению изображений ISAR. На рисунках 17a-c показаны три типичные конфигурации наблюдения с разным азимутом результатов изображения, а на рисунке 18a-c показаны три типичные конфигурации наблюдения с разным азимутом диаграммного усиления. Результаты визуализации для метода SBR с графическим ускорением и RL-GO в FEKO с различными параметрами наблюдения показаны на рис. 18a, б и в соответственно.

На рисунках 17a-c показаны три типичные конфигурации наблюдения с разными аз- θ = 120. На 18 угол падения установлен как, а остальные параметры представляют собой одинаковые имитационные диапазоны сканирования. Результаты визуализации ISAR для трех типичных конфигураций наблюдений показаны как на рисунке 16. На рисунках 18a-c поля обратного рассеяния рассчитываются нашим графическим процессором — с различными диапазонами азимутального сканирования показаны на рисунках 18a, б и с соответственно. ускоренный метод SBR. На рисунке 18d-i поля обратного рассеяния получены с помощью RL-GO. На рисунке 18 угол падения установлен как θ = 120, а остальные параметры такие же, как на рисунке 16. На рисунках 18a-c поля обратного рассеяния рассчитаны по нашему λ (ж-т) RL-GO при плотности лучей 100. Прокладывая пятна в рассеянии, как и в методе SBR с графическим ускорением. На рисунке 18d-f поля обратного рассеяния получены с помощью RL-GO в FEKO. И SBR с графическим ускорением, и RL-GO в FEKO — это методы, основанные на лучах. Сравнение результатов изображения ISAR на рисунках 18a-c с рисунками 18d-f и рисунками. Эти пятна рассеяния связаны с механизмом рассеяния электромагнитных волн. 18g-i демонстрирует осуществимость и эффективность нашей схемы за счет объединения GPU-ускорения и механизма трассировки лучей. Из-за пренебрежения дифракционным полем, возникающим из-за SBR с алгоритмом РЛ, это приводит к искажению изображений ISAR. На рисунках 19a-c показаны три типичные конфигурации наблюдения с разным азимутом результатов изображения, а на рисунке 20a-c показаны три типичные конфигурации наблюдения с разным азимутом диаграммного усиления. Результаты визуализации для метода SBR с графическим ускорением и RL-GO в FEKO с различными параметрами наблюдения показаны на рис. 18a, б и в соответственно.




Рисунок 17. Три типичные конфигурации наблюдения с разными углами азимута при фиксированном угле падения θ = 20°; (а) φ = 45°; (б) φ = 135°; (в) φ = 45°; (г) φ = 45°; (д) φ = 135°; (е) φ = 45°.




Рис.	18a,d 18a,d,е,ф,г,е, 18с,ф,Рис. 18с, f Рис. 19 показывает	SBR		РЛ-ГО	
		SBR		РЛ-ГО	
		Время (с)	Память (МБ)	Время (с)	Память (МБ)
		264,7	72,4	165,6	194,6
		271,2	74,2	155,6	202,4
		264,7	74,2	170,2	196,9
		287,2	77,1	176,4	196,9

Хвост самолета хорошо виден на рисунке 21а. Это также происходит на рисунках 21с,ф, куда указывают белые стрелки на рисунках 21с,ф. Хорошо видно, что разбросанные пятна проб, появившиеся в местах, указанных стрелками, не являются конструктивной информацией самолета. Хорошо установленный факт, что электромагнитные волны проявляют эффект многолучевости во время

распространение. Это явление означает, что падающая волна пересекает множество пути достижения назначенного пункта приема. Изменения в данных фазовой истории, вызванные этими разные пути могут накладываться друг на друга, что приводит к искажению фазовой истории. Таблица 6 показывает сравнение времени вычислений и пиковой памяти на рисунке 21.

Поларизация:

BB




Рис. 19. CAD-модель большого самолета с электрической системой.




Рисунок 20. Типичные конфигурации наблюдения с разными углами азимута при фиксированном инциденте. Рисунок 20. Типичные конфигурации наблюдения с разными углами азимута при фиксированном инциденте. Рисунок 20. Типичные конфигурации наблюдения с разными углами азимута при фиксированном инциденте.

Таблица 5. Параметры моделирования ISAR для рисунка 21.

Параметр	Ценить
f_0	1,75 ГГц
B	3 ГГц
ϕ	90
θ	60
x	0,05 м
y	0,05 м
Точки отбора проб поляризации	600 BB


Таблица 6. Время вычислений и пиковая нагрузка памяти для рисунка 21.

	СБР		РЛ-ГО	
	Время (ч)	Память (МБ)	Время (ч)	Память (МБ)
Рисунок 21а,г	20,1	141,2	16,3	269,6
Рисунок 21б,д	19,6	140,7	15,5	258,5
Рисунок 21в,е	20,7	145,6	16,9	273,1

Численное моделирование изоб (а) и (б) ясно показывает, что (а) и (б) типичные центры рассеяния, а также профили целей могут наблюдаться при больших азимутах наблюдения. Рисунок 21. Типичные конфигурации наблюдения с разными углами азимута при фиксированном инциденте. Рисунок 21. Типичные конфигурации наблюдения с разными углами азимута при фиксированном инциденте. Рисунок 21. Типичные конфигурации наблюдения с разными углами азимута при фиксированном инциденте.

(a) Искажение фазовой истории является распространенной проблемой лучевых методов. Таким образом, явные боковые лепестки

(а) $\theta = 60^\circ$; (б) $\theta = 75^\circ$; (в) $\theta = 90^\circ$; (г) $\theta = 105^\circ$; (д) $\theta = 120^\circ$. $\varphi = 45 - 135$; (ж) $\varphi = 45 - 45$; (з) $\varphi = 45 - 135$; (и) $\varphi = 45 - 45$.



В этой статье рассматривается новый метод прятяющих лучей, основанный на ускорении графического процессора и дерева BVH. представлено для моделирования изображений ISAR. Он использует C++AMP для достижения параллелизма с графическим процессором. вычисление ускорения, при котором древовидная структура BVH строится в соответствии с целевую структуру, тем самым повышая эффективность пересечения лучей. Метод SAH включен в разделение сцены на ограничивающую рамку, эффективно смягчая влияние ограничивающих рамок. наложение блоков на эффективность прохождения лучей древовидной структуры BVH. Чтобы эффективно выполнять моделирование изображений ISAR, алгоритм ускоренной визуализации АД на базе графического процессора был разработан на основе CUDA. Точность SBR с графическим ускорением подтверждена путем сравнения RCS, рассчитанного нашим методом SBR, с полученным RL-GO в ФЕКО. Показано, что представленный SBR с графическим ускорением показывает хорошую валидность. и надежность. Для моделирования изображений ISAR используется A380 и упрощенный самолет.

В качестве примера модели поля обратного рассеяния рассчитывались с использованием ускорения на графическом процессоре.

Алгоритм SBR при больших углах азимута, $\varphi = 90^\circ$, и широкая полоса пропускания 3 ГГц.

обраторассеянные эхо фокусируются с использованием алгоритма визуализации АД с ускорением графического процессора, а сфокусированные изображения ISAR нашего метода SBR с графическим ускорением хорошо согласуются с метода RL-GO от ФЕКО, что указывает на осуществимость и эффективность нашего ускорения на графическом процессоре.

Алгоритм визуализации BP ISAR. Моделирование показывает, что сильные центры рассеяния также поскольку профили целей можно четко наблюдать на изображениях ISAR под большими углами наблюдения и широкие полосы пропускания. На сфокусированных изображениях ISAR можно наблюдать очевидные боковые лепестки из-за

фазовой истории электромагнитных волн, искажающихся в результате мультипольного рассеяние. Численное моделирование также показывает, что результаты изображений ISAR являются сильно чувствителен к углам наблюдения. В дальнейшем настоящая работа будет расширена. для получения изображений ISAR роя целей, а также 3D изображений ISAR путем разработки эффективного алгоритм электромагнитного моделирования путем объединения SBR и PTD с графическим ускорением для с учетом краевой дифракции.

Вклад авторов: методология, JC, RZ, PY и RW; программное обеспечение, JC; проверка, JC; формальный анализ, JC; моделирование трассировки лучей, JC; расследование, JC и PY; ресурсы, PY; письмо — оригинал подготовка проекта, JC; написание — обзор и редактирование, PY; визуализация, ДК; надзор, ПЯ; проект администрация, JC и PY. Все авторы прочитали и согласились с опубликованной версией рукопись.

Финансирование: работа частично поддерживалась Национальным фондом естественных наук Китая. [Грант № 62061048, 62261054 и 62361054], частично предоставленный Шэньсийским центром исследований и разработок. Программа [гранты № 2023-YBGY-254 и 2024GXVBM-108], частично предоставленная Natural Science Basic. План исследований в провинции Шэньси, Китай (грант № 2023-JC-YB-539), частично выполненный аспирантом Программа инноваций в образовании Университета Яньань (грант № YCX2024086).

Заявление о доступности данных: данные, представленные в этом исследовании, доступны по запросу от соответствующий автор.

Благодарности: Авторы благодарят редакторов и рецензентов за конструктивные предложения.

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Сокращения

В данной рукописи использованы следующие сокращения:

БП	Обратная проекция
БВХ	Иерархии ограничивающих томов
C++AMP C++:	ускоренный массовый параллелизм
Унифицированная архитектура устройств CUDA Computing	
САПР	Системы автоматизированного проектирования
Процессор	Центральное процессорное устройство
Эквивалентный дипольный момент	
БПФ	Быстрое преобразование Фурье
Графический процессор	
ИДТИ	Геометрическая оптика
ИСАР	Радар с обратной синтезированной апертурой
ОБПФ	Обратное быстрое преобразование Фурье
Kd-дерево	K-мерное дерево
МОМ Метод моментов	
ПТД	Физическая теория дифракции
ПО	Физическая оптика
УИК	Идеальный электрический проводник
РКС	Сечение радара
RL-GO Ray	представляет геометрическую оптику
RMSE	Среднеквадратическая ошибка
СБР	Стреляющий и прыгающий луч
САК	Эвристика площади поверхности
SMS	Потоковые мультипроцессоры
ИП	Потоковые процессоры
SIMT	Одна инструкция, несколько потоков
TDSBR	Стреляющий и отскакивающий луч во временной области
TDPO	Физическая оптика во временной области

Рекомендации

1. Бхалла, Р.; Линг, Х. Формирование изображения ISAR с использованием бистатистических данных, вычисленных с помощью техники стрельбы и отражения лучей. Дж. Электромагн. Волны Appl. 1993, 7, 1271–1287. [\[Перекрестная ссылка\]](#)

2. Он, ХУ; Чжоу, ХУ; Куи, Т.Дж. Быстрое моделирование целей с помощью изображений 3D-ISAR под произвольными углами обзора с помощью неравномерного быстрого преобразования Фурье (NUFFT). IEEE Транс. Антенны Пропаг. 2012, 60, 2597–2602. [\[Перекрестная ссылка\]](#)

3. Чжан К.; Ван, СФ; Джин, Дж. М. Широкополосное моностатическое расчет RCS и ISAR для больших и глубоких открытых полостей. IEEE Транс. Антенны Пропаг. 2018, 66, 4180–4193. [\[Перекрестная ссылка\]](#)

4. Прикетт, М.; Чен, К. Принципы радиолокации с обратной синтезированной апертурой/ISAR/изображений. В материалах EASCON 1980, Конференции по электронике и аэрокосмическим системам, Арлингтон, Вирджиния, США, 29 сентября – 1 октября 1980 г.; стр. 340–345.

5. Гарсиа-Фернандес, А.Ф.; Йесте-Охеда, ОА; Гражал, Дж. Фасетная модель движущихся целей для построения изображений ISAR и обратного радиолокационного рассеяния Моделирование. IEEE Транс. Аэроsp. Электрон. Сист. 2010, 46, 1455–1467. [\[Перекрестная ссылка\]](#)

6. Ли, Дж.И.; Юн, диджей; Ким, НД; Ян, Вайоминг; Мьюнг, Нью-Хэмпшир Формирование изображений Fast ISAR под многоаспектными углами с помощью съемки и Прыгающие лучи. Антенны IEEE Wirel. Пропаг. Летт. 2018, 17, 1020–1023. [\[Перекрестная ссылка\]](#)

7. Го, Г.; Го, Л.; Ван, Р.; Ли, Л. Система визуализации ISAR для больших и сложных целей с использованием TDSBR. IEEE-антенны Вирел. Пропаг. Летт. 2021, 20, 1928–1932. [\[Перекрестная ссылка\]](#)

8. Мэн, В.; Ли, Дж.; Си, УД; Го, LX; Ли, З.Х.; Вэнь, С.К. Улучшенный метод стреляющих и отскакивающих лучей на основе дерева смешивания для электромагнитного рассеяния нескольких движущихся целей и анализа эха. IEEE Транс. Антенны Пропаг. 2024, 72, 2723–2737. [\[Перекрестная ссылка\]](#)

9. Ян, П.Дж.; Ву, Р.; Рен, ХС; Чжан, ЮК; Чжао, Ю. Доплеровские спектры электромагнитной волны, рассеянной объектом, летящим над изменяющейся во времени нелинейной морской поверхностью. Дж. Электромагн. Волны Appl. 2019, 33, 2175–2198. [\[Перекрестная ссылка\]](#)

10. Линг, Х.; Чжоу, RC; Ли, С.В. Стреляющие и отскакивающие лучи: расчет ЭПР полости произвольной формы. IEEE Транс. Антенны Пропаг. 1989, 37, 194–205. [\[Перекрестная ссылка\]](#)

11. Сюй, Ф.; Джин, Ю. К. Двухнаправленная аналитическая трассировка лучей для быстрого расчета сложного рассеяния от большой электрической цели на случайно шероховатая поверхность. IEEE Транс. Антенны Пропаг. 2009, 57, 1495–1505. [\[Перекрестная ссылка\]](#)

12. Тао, Ю.; Лин, Х.; Бао, Х. Метод стреляющих и отражающих лучей на основе графического процессора для быстрого прогнозирования RCS. IEEE Транс. Антенны Пропаг. 2010, 58, 494–502. [\[Перекрестная ссылка\]](#)

13. Мэн, В.; Ли, Дж.; Го, LX; Ян, QJ. Ускоренный метод SBR для прогнозирования RCS электрически большой цели. IEEE-антенны Вирел. Пропаг. Летт. 2022, 21, 1930–1934. [\[Перекрестная ссылка\]](#)

14. Баден, Дж. М.; Трипп, В.К. Обращение лучей в расчетах ЭПР СБР. В материалах 31-го Международного обзора прогресса в области Прикладная вычислительная электромагнетика (ACES), Вильямсбург, Вирджиния, США, 22–26 марта 2015 г.; стр. 1–2.

15. Фэн, Т.Т.; Го, Л.К. Улучшенный алгоритм трассировки лучей для расчета электромагнитного рассеяния электрически больших целей на основе SBR. Антенны IEEE Wirel. Пропаг. Летт. 2021, 20, 818–822. [\[Перекрестная ссылка\]](#)

16. Юн, К.Ц.; Фу, В.К. Эффективная реализация метода высокочастотного SBR-PO на графическом процессоре. Антенны IEEE Wirel. Пропаг. Летт. 2013, 12, 941–944. [\[Перекрестная ссылка\]](#)

17. Ву, Р.; Ву, ВУ; Он, ПХ; Го, Кентукки; Шэн, XQ Алгоритм разложения быстрых плоских волн для строгого анализа рассеяния Рой целей. IEEE Транс. Антенны Пропаг. 2023, 71, 7426–7437. [\[Перекрестная ссылка\]](#)

18. Донг, К.-Л.; Го, Л.-Х.; Мэн, Х. Ускоренный алгоритм на основе GO-PO/PTD и CWMFSM для рассеяния ЭМ от корабля над морской поверхностью и формирования PCA-изображений. IEEE Транс. Антенны Пропаг. 2020, 68, 3934–3944. [\[Перекрестная ссылка\]](#)

19. Донг, К.-Л.; Го, Л.-Х.; Мэн, Х.; Ван, Ю. Ускоренный SBR для электромагнитного рассеяния на электрически больших сложных объектах. Антенны IEEE Wirel. Пропаг. Летт. 2018, 17, 2294–2298. [\[Перекрестная ссылка\]](#)

20. Мэн, В.; Ли, Дж.; Чай, СР; Си, УД; Вэнь, СК; Лю, Р.Ф. Усовершенствованный метод SBR-PTD для измерения рассеяния электромагнитного излучения от движущейся мишени. В материалах симпозиума Международного общества прикладной вычислительной электромагнетики 2023 г. (ACES-Китай), Ханчжоу, Китай, 15–18 августа 2023 г.; стр. 1–3.

21. Ли, ХЗ; Донг, CL; Мэн, Х.; Го, LX; Вэй, К.Х. Новый гибридный метод MoM-SBR на основе эквивалентного дипольного момента для расчета электромагнитного рассеяния электрически больших сложных целей. В материалах Международной конференции по микроволновым и миллиметровым технологиям 2023 года (ICMMT), Циндао, Китай, 14–17 мая 2023 года; стр. 1–3.

22. Ван З.; Вэй, Ф.; Хуанг, Ю.; Чжан, Х.; Чжан З. Улучшенный метод рентгенологической визуализации, основанный на принципе пошагового расчета. В материалах 2-го Китайского международного симпозиума по поиску и спасанию (CISS) 2021 г., Шанхай, Китай, 3–5 ноября 2021 г.; стр. 1–5.

23. Донг, Л.; Хан, С.; Чжу, Д.; Мао, Х. Модифицированный алгоритм полярного формата для сильно прищуренных ракетных поисково-спасательных систем. IEEE Geosci. Дистанционная чувствительность Lett. 2023, 20, 1–5. [\[Перекрестная ссылка\]](#)

24. Боаг, А.Г.А. Обратнопроеекционное изображение движущихся объектов. IEEE Транс. Антенны Пропаг. 2021, 69, 4944–4954. [\[Перекрестная ссылка\]](#)

25. Чжан, М.; Рен, З.; Чжан, Г.; Чжан, К. ТГц ISAR-изображение с использованием алгоритма обратной проекции с фазовой компенсацией и ускорением графического процессора. Дж. Инфракрасный Миллим. Волны 2022, 41, 448–456. [\[Перекрестная ссылка\]](#)

26. Арикан О.; Мансон, округ Колумбия, младший. Новый алгоритм обратной проекции для SAR и ISAR в режиме прожектора. В материалах Высокого Speed Computing II, Лос-Анджелес, Калифорния, США, 17–18 января 1989 г.; стр. 107–117.

27. Гонг, Х.; Лю, Ю.; Чен, Х.; Ван, К. Оптимизация сцены с помощью алгоритма обратной проекции на основе графического процессора. Дж. Суперкомпьютер. 2023, 79, 4192–4214. [\[Перекрестная ссылка\]](#)

28. Го, Г.; Го, Л.; Ван, Р.; Лю, В.; Ли, Л. Моделирование переходного рассеянного эха и визуализация ISAR для составного объекта-океана Сцена на основе метода TDSBR. Remote Sens. 2022, 14, 1183. [\[CrossRef\]](#)

29. Вc, Т.-П.; Конг, З.; Он, З.; Дин, Д. Ускоренный итерационный метод физической оптики во временной области для электрического анализа Большие и сложные цели. *Электроника* 2022, 12, 59. [\[CrossRef\]](#)

30. Го, Г.; Го, Л.; Ван, Р. Алгоритм изображения ISAR с использованием рассеянного эха во временной области, моделируемого методом TDPO. *Антенны IEEE Wirel. Пропаг. Летт.* 2020, 19, 1331–1335. [\[Перекрестная ссылка\]](#)

31. Чжоу Дж.; Хан, Ю. Анализ характеристик электромагнитного рассеяния плазменных мишеней на основе стреляющих и отражающихся лучей. *метод. АИП Адв.* 2019, 9, 065106. [\[CrossRef\]](#)

32. Гордон, В.Б. Высокочастотные приближения к интегралу рассеяния физической оптики. *IEEE Транс. Антенны Пропаг.* 1994, 42, 427–432. [\[Перекрестная ссылка\]](#)

33. Фан, ТТ; Чжоу, Х.; Ю, ВМ; Чжоу, ХУ; Кюи, Т. Дж. Линейно-интегральные представления физико-оптических рассеянных полей во временной области. *IEEE Транс. Антенны Пропаг.* 2017, 65, 309–318. [\[Перекрестная ссылка\]](#)

34. Ляо, К. Исследование моделирования рассеяния корабля в ближнем поле на морской поверхности на основе высокочастотного метода (на китайском языке). Магистерская диссертация, Китайский университет электронных наук и технологий, Чэнду, Китай, 2021 г. Доступно онлайн: https://kns.cnki.net/kcms2/article/abstract?v=n6BwBobH4uvU7PG733EVJdhS9-f9LApXUEAHZK60Kgv6ciotFWwf1.1njOZZqPyjAOLTnfvU-beMgAqMR8bIHbC9mFOJ0F5tkD-vf1xHSqT6eY_XonBN7ouPAQRKMghtFziV-7qPBjXZhfcEiaH_takq8r-JoHJuM61BQbTbKyScQeiPY8_hM3AAmLBajTfo9XIwNvOUOSI=&uni (по состоянию на 29 июля 2024 г.).

35. Страттон, Дж.А.; Чу, Л. Теория дифракции электромагнитных волн. *Физ. Ред.* 1939, 56, 99. [\[CrossRef\]](#)

36. Чу, ЖЖ; Страттон, Дж. А. Эллиптические и сфероидальные волновые функции. *Дж. Математика. Физ.* 1941, 20, 259–309. [\[Перекрестная ссылка\]](#)

37. Он, Х.-У.; Ван, Х.-Б.; Чжоу, Х.; Чжао, Б.; Кюи, Т.-Ж. Быстрое моделирование изображений целей с произвольными ракурсами ISAR с использованием нового Метод СБР. *Прог. Электромагн. Рез. Б* 2011, 28, 129–142. [\[Перекрестная ссылка\]](#)

38. Го, Г.; Го, Л.; Ван, Р. Исследование ближнепольного рассеяния мишени при антенном облучении методом TDSBR. *IEEE Доступ* 2019, 7, 113476–113487. [\[Перекрестная ссылка\]](#)

39. Тан, Х.; Фэн, Ю.; Гонг, К. Мо. Алгоритм M-PO/SBR, основанный на совместной платформе и смешанной модели. *Пер. Нанкинский университет. Аэронавт. Астронавт.* 2019, 36, 589–598. [\[Перекрестная ссылка\]](#)

40. Ли, Дж.; Мэн, В.; Чай, С.; Го, Л.; Си, Ю.; Вэнь, С.; Ли, К. Ускоренный гибридный метод электромагнитного рассеяния Составная модель цели-земли и ее прожекторное радиолокационное изображение. *Remote Sens.* 2022, 14, 6632. [\[CrossRef\]](#)

41. Чжу Р. Ускорение микромагнитного моделирования с помощью C++ AMP на графических процессорах. *Вычислить. наук. англ.* 2016, 18, 53–59. [\[Перекрестная ссылка\]](#)

42. Сихай, В.; Ху, З.; Хаотянь, П.; Лу, К. Ускоренный параллелизм в численном моделировании с помощью C++ AMP. В материалах 2016 года Семинар: Workshop High Performance Computing, Пекин, Китай, 14–16 ноября 2016 г.; стр. 53–55.

43. Винтерс, Э. Быстрая и простая параллельная обработка на графических процессорах с использованием C++ AMP. *Дж. Компьютер. наук. Колл.* 2016, 31, 27–33.

44. Шьямала, К.; Киран, КР; Раджешвари, Д. Разработка и реализация умножения цепочек матриц на базе графического процессора с использованием C++AMP. В материалах Второй международной конференции по электрическим, компьютерным и коммуникационным технологиям (ICECCT) 2017 г., Коимбатур, Индия, 22–24 февраля 2017 г.; стр. 1–6.

45. Дамкьер, Дж. Стековое обнаружение столкновений BVN для физического моделирования; Университет Копенгагена Universitetsparken: Копенгаген, Дания, 2007 г.; Доступно онлайн: <http://image.diku.dk/projects/media/jesper.damkjaer.07.pdf> . (по состоянию на 29 июля 2024 г.).

46. Чанг, С.; Чой, М.; Юн, Д.; Ким, С. Сравнение BVN и KD-дерева для ускорения GPGPU на реальных мобильных устройствах. In *Proceedings of the Frontier Computing: Theory, Technologies and Applications (FC 2018)*, Кюсю, Япония, 9–12 июля 2019 г.; стр. 535–540.

47. Сопин Д.; Боголепов Д.; Ульянов Д. Построение SAN BVN в реальном времени для динамических сцен с трассировкой лучей. В материалах График'2011, Москва, Россия, 26–30 сентября 2011 г.; стр. 74–77.

48. Хуэйпэн, З.; Юнлинг, В.; Ди, Х.; Сюян, К. Модифицированный алгоритм обратной проекции для биатомического ISAR-изображения космических объектов. В материалах Международной конференции IEEE по обработке сигналов, связи и вычислениям (ICSPCC) 2016 г., Гонконг, Китай, 5–8 августа 2016 г.; стр. 1–5.

49. Сяо, Д. Исследование ISAR-изображений космических целей с использованием технологии ВР; Нанкинский университет: Нанкин, Китай, 2017.

50. Пу, Л.; Чжан, Х.; Ага.; Вэй, С. Быстрый трехмерный алгоритм обратной проекции в частотной области на основе графического процессора. В материалах конференции IEEE Radar Conference 2018 (RadarConf18), Оклахома-Сити, штат Оклахома, США, 23–27 апреля 2018 г.; стр. 1173–1177.

51. Ли, З.; Цю, Х.; Ян, Дж.; Мэн, Д.; Хуанг, Л.; Сонг, С. Эффективный алгоритм ВР на основе TSU-ICSI в сочетании с параллельным графическим процессором Вычисления. *Remote Sens.* 2023, 15, 5529. [\[CrossRef\]](#)

52. Афиф, М.; Саид, Ю.; Атри, М. Ускорение алгоритмов компьютерного зрения с помощью графических процессоров NVIDIA CUDA. *Класт. Вычислить.* 2020, 23, 3335–3347. [\[Перекрестная ссылка\]](#)

53. Уфимцев, П.Я. Элементарные краевые волны и физическая теория дифракции. *Электромагнетизм* 1991, 11, 125–160. [\[Перекрестная ссылка\]](#)

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.



Статья

Раскрытие бизнес-ценности: интеграция на основе искусственного интеллекта

Принятие решений в системах финансовой отчетности

Алин Эмануэль Артене 1,* , Аура Эмануэла Домил , 2  и Лариса Иваску 

¹ Департамент менеджмента, факультет менеджмента в производстве и транспорте, Политехнический университет Тимишоары, ул. Ремус, 14, 300009 Тимишоара, Румыния; larisa.ivascu@upt.ro
² Кафедра бухгалтерского учета и аудита, факультет экономики и делового администрирования, Западный университет Тимишоары, 300223 Тимишоара, Румыния; aura.domil@e-uvt.ro
* Переписка: alin.artene@upt.ro

Аннотация: В этой исследовательской статье исследуется синергия между искусственным интеллектом (ИИ), цифровой трансформацией (DT) и системами финансовой отчетности в бизнес-контексте. Центральная тема исследует, как организации улучшают свои процессы принятия решений путем интеграции технологий искусственного интеллекта в инициативы по цифровой трансформации, особенно в финансовой отчетности. В центре внимания находится понимание того, как синергия этих интегрированных систем может раскрыть значительную ценность бизнеса, стимулировать стратегические инновации и повысить общий уровень финансовой аналитики за счет внедрения интеллектуальных методологий принятия решений на основе данных. Используя передовые возможности аналитики, автоматизации и адаптивной поддержки принятия решений, организации справляются со сложностями быстро развивающейся бизнес-среды, в которой нейронные сети становятся ценным инструментом для калибровки результатов в среде финансового учета, демонстрируя эффективность в обработке сложных финансовых данных. выявление закономерностей и прогнозирование, открывая новую. Внедрение матрицы выигрышей теории игр в этот инструмент принятия решений ИИ добавляет стратегическую основу для анализа взаимодействия между лицами, принимающими решения, рассмотрения стратегического выбора и результатов в динамичном и конкурентном контексте.

Ключевые слова: цифровая трансформация; системы принятия решений; интегрированные системы; нейронные сети; финансовая отчетность предприятия; Матрица выигрышей теории игр



Цитирование: Артене А.Е.; Домиль, А.Е.; Иваску, Л.

Раскрытие ценности бизнеса: интеграция процесса принятия решений на основе искусственного интеллекта в системы финансовой отчетности. *Электроника* 2024, 13, 3069. <https://doi.org/10.3390/electronics13153069>

Академический редактор: Доменико Урсиньо

Поступила: 12 июля 2024 г.
Пересмотрено: 24 июля 2024 г.
Принято: 30 июля 2024 г.
Опубликовано: 2 августа 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

Автоматизация, искусственный интеллект и анализ данных приводят к значительным изменениям в работе финансовых учреждений. В постоянно меняющемся мире финансовой отчетности организации сталкиваются с насущной необходимостью использовать преобразующий потенциал цифровых технологий. Влияние цифровизации на финансы неоспоримо. Сдвиг парадигмы в сторону цифровой трансформации представляет собой критический момент, когда компании должны не только адаптироваться, но и внедрять инновации, чтобы оставаться конкурентоспособными на мировом рынке. Центральное место в целях этой эволюции занимает интеграция технологий искусственного интеллекта (ИИ), которые открывают беспрецедентные возможности для революционного изменения стратегического управления в системах экономической финансовой отчетности. Процесс контроля в этой парадигме развивается от жесткого наблюдения к динамической оркестровке.

Встроенные системы искусственного интеллекта, оснащенные сложными алгоритмами, демонстрируют способность непрерывно учиться на потоках данных, адаптироваться к меняющимся закономерностям и принимать решения в режиме реального времени. Это представляет собой переход от детерминированной модели управления к более адаптивной и вероятностной структуре, в которой контроль осуществляется посредством алгоритмического управления и непрерывных циклов обратной связи.

В эпоху постпандемической цифровой трансформации интеграция технологий искусственного интеллекта является краеугольным камнем для государственных и частных экономических субъектов, которые стремятся ориентироваться в сложном ландшафте финансовой отчетности и экономической производительности.

точность и ловкость. Конвергенция искусственного интеллекта и оцифровка систем финансовой отчетности [1] не только представляют собой сдвиг технологической парадигмы, но и приводят к глубокому переопределению механизмов контроля и процессов управления. Интегрированные системы искусственного интеллекта меняют структуру контроля и расширяют возможности лиц, принимающих решения, в динамичном контексте финансовой отчетности в условиях цифровой трансформации.

По мере того, как предприятия вступают в путь цифровой трансформации и оцифровки [2], стратегическое и субсидируемое внедрение технологий искусственного интеллекта обещает раскрыть беспрецедентную ценность бизнеса. Традиционные системы финансовой отчетности, основанные на детерминистских методологиях, сейчас находятся на перепутье, поскольку организации стремятся внедрить передовые алгоритмы искусственного интеллекта. Интеграция машинного обучения, прогнозной аналитики и когнитивных вычислений в эти системы открывает новое измерение автономии и адаптивности. Поскольку ИИ становится активным участником процессов принятия решений, контуры механизмов контроля должны быть переоценены.

Традиционным иерархическим моделям бросает вызов распределенный характер принятия решений во встроенных системах искусственного интеллекта [3], где алгоритмы обучаются, адаптируются и вносят свой вклад автономно. Необходимость понимания сложностей и последствий этой интеграции стала первостепенной, особенно с точки зрения ее влияния на принятие решений по финансовой отчетности. Традиционные системы отчетности, несмотря на то, что они являются неотъемлемой частью функционирования организации, сегодня нуждаются в развитии. Возникает следующий вопрос: как разумная интеграция технологий искусственного интеллекта может улучшить процессы принятия решений в контексте финансовой отчетности в процессе цифровой трансформации?

На рис. 1 показано принятие решений на основе искусственного интеллекта в ходе цифровой трансформации. Сюда входят инициативы по цифровой трансформации, интеграция искусственного интеллекта, улучшение процесса принятия решений, преимущества, варианты использования, соображения, будущие тенденции, стратегии внедрения и показатели измерения. Каждое из этих направлений важно в эволюции цифровизации. Оценивая каждое

направление, можно констатировать следующее:

- Инициативы цифровой трансформации: они представляют собой шаги, способствующие ЦТ. Могут быть включены компоненты, которые способствуют успеху процесса DT, стратегические элементы, а также возможности и проблемы.

- Интеграция ИИ: сюда входит определение важной роли ИИ в ЦТ, различных типов связанных технологий, а также реализации возможностей и решений. Все это способствует важной поддержке процесса DT.
- Совершенствование процесса принятия решений: это относится к использованию данных для получения конкурентных преимуществ, прогнозной аналитике и автоматизации организационных процессов, а также оптимизации процессов посредством эффективного принятия решений.


- Выгоды: выгоды, выявленные бенефициарами, многочисленны, среди них повышение точности, эффективности времени и затрат, улучшение качества обслуживания клиентов и другие сопутствующие преимущества.

- Пример: оценивая конкретные элементы, в которых можно использовать ИИ, мы можем упомянуть финансовую отчетность, управление операциями, приложения ИИ для работы с клиентами и

многие другие.

- Рассмотрение: важными элементами, которые необходимо оценить в этом подходе, являются этические последствия, безопасность и сотрудничество человека и искусственного интеллекта.

- Будущие тенденции: эта область значительно расширяется, и будущие подходы следует предвидеть на организационном уровне посредством хорошо продуманных стратегий и подходов (новые тенденции, эволюция области и технологические подходы).
- Стратегии реализации: элементы стратегического управления подходят на организационном уровне для обеспечения хорошего соответствия технологическому прогрессу.
- Метрики измерения: весь этот подход должен быть измерен, а метрики показателей производительности и успеха внедрения ИИ включают правильные организационные подходы.



2. Обзор литературы
2. Обзор литературы

[illegible]

преобразующие в актуальную бизнес-модель и способностей в развивающейся финансовой сфере. В контексте современной экономики

как использование данных другими влияет на результаты рынка [5]. Это исследование предполагает включение больших данных в современные экономические и финансовые теории. Примечательно, что одно из приложений предполагает использование больших данных для улучшения процесса принятия решений участниками финансового рынка, влияя на цены компаний, стоимость капитала и динамику инвестиций.

Концепция цифровой трансформации финансовой отчетности широко исследовалась в литературе. Такие ученые, как авторы [7,8], обсуждали эволюцию систем финансовой отчетности от ручных процессов к передовым цифровым платформам. Переход к облачным решениям, автоматизация задач по вводу данных и использование передовых инструментов аналитики были определены как ключевые компоненты цифровой трансформации в финансовой отчетности [9].

Исследование Соренсена [10] изучает важность согласования финансовых решений с предпочтениями заинтересованных сторон. Ссылка. [10] подчеркивает необходимость в инструментах, учитывающих точки зрения различных заинтересованных сторон, таких как руководство компании и акционеры.

Интеграция инструментов принятия решений на основе искусственного интеллекта, основанных на нейронных сетях, предлагает механизм согласования стратегического выбора с предпочтениями ключевых заинтересованных сторон.

В литературе также признаются проблемы, связанные с интеграцией искусственного интеллекта и цифровой трансформации в финансовой отчетности. Обсуждались проблемы, связанные с конфиденциальностью данных, соблюдением нормативных требований и потребностью в квалифицированных специалистах, способных ориентироваться на стыке финансов и искусственного интеллекта [3,11]. Однако исследования также подчеркивают возможности экономии затрат, повышения эффективности и стратегические преимущества, которые возникают в результате успешной реализации [12]. Многочисленные исследования подчеркивают важность финансовых KPI для измерения эффективности и принятия стратегических решений в организациях [13].

Такие показатели, как рентабельность инвестиций (ROI), прибыль на акцию (EPS) и размер прибыли, признаны важнейшими показателями финансового здоровья. Исследователи утверждают, что включение этих ключевых показателей эффективности в нейронные сети может повысить точность финансовых прогнозов и систем поддержки принятия решений [14,15].

Исследование пересечения теории игр и принятия финансовых решений [16] исследует, как стратегические взаимодействия между участниками рынка, находящиеся под влиянием асимметрии информации и конкуренции, влияют на финансовые результаты. Исследование, возможно, не фокусируется непосредственно на ключевых показателях эффективности, но дает представление о динамике принятия решений. Хотя, возможно, не существует обширной литературы, явно объединяющей финансовые KPI, принятие решений и теорию игр, некоторые исследования дают основу для понимания взаимосвязи этих концепций. Обращаясь к прозрачности и интерпретируемости моделей принятия решений ИИ, Ref. [17] обсуждает важность объяснимости для завоевания доверия и признания инструментов ИИ при принятии решений, особенно в таких чувствительных областях, как здравоохранение и финансы.

Обзор литературы указывает на растущее количество исследований, подчеркивающих разнообразные применения, проблемы и этические соображения, связанные с интеграцией инструментов ИИ в процесс принятия решений. Понимание влияния ИИ в различных областях обеспечивает основу для будущих разработок в создании более эффективной, прозрачной и этичной системы поддержки принятия решений.

В последние годы бухгалтерские и аудиторские компании воспользовались потенциалом искусственного интеллекта, чтобы революционизировать традиционные процессы в финансовых учреждениях, и разработали приложения машинного обучения в финансах. JP Morgan Chase, мировой лидер в области финансовых услуг, разработал платформу Contract Intelligence, или COiN, инструмент на основе искусственного интеллекта, предназначенный для проверки юридических документов и извлечения важных данных и положений, сокращая до 360 000 часов в год, требуя значительных человеческих ресурсов и повышая точность и масштабируемость операций, устанавливая новый стандарт эффективности финансовой отчетности. Еще одним убедительным примером является компания Deloitte, ведущая компания в сфере услуг аудита и обеспечения качества, которая использовала ACL Analytics, сложное программное обеспечение для анализа данных, чтобы усовершенствовать свои процессы аудита. Этот инструмент использует возможности искусственного интеллекта и машинного обучения для анализа огромных объемов финансовых данных, выявления аномалий, тенденций и закономерностей, которые требуют дальнейшего изучения. Интегрируя нейронные сети, аудиторы могут сконцентрировать свои усилия на областях высокого риска, тем самым улучшая качество

предоставление клиентам ценных рекомендаций, основанных на данных, способствуя более обоснованному принятию решений и стратегическому планированию.

3. Материалы и методы.

В этой исследовательской работе используется комплексная фундаментальная методология исследования, позволяющая раскрыть ценность бизнеса за счет интеграции принятия решений на основе искусственного интеллекта с цифровой трансформацией в системах финансовой отчетности. Логический процесс, описанный в этой методологии, служит пошаговой дорожной картой, направляющей исследование пересечения искусственного интеллекта (ИИ) и цифровой трансформации в экономике в контексте цифровизации финансовой отчетности. Основная цель — разработать теоретическую основу, которая улучшит процессы принятия решений за счет ассимиляции передовых технологий искусственного интеллекта в существующие системы финансовой отчетности. В ходе этого исследования мы прошли систематические этапы, начиная с определения проблемы исследования, за которым следовал обширный обзор литературы для сбора соответствующей информации об искусственном интеллекте, цифровой трансформации и современных системах финансовой отчетности. Затем теоретическая основа была нанесена на карту путем синтеза существующих знаний и выявления пробелов в текущем понимании. Впоследствии авторы сформулировали план исследования, которым будет руководствоваться эмпирическое исследование.

Интеграция принятия решений на основе искусственного интеллекта с цифровой трансформацией в системы финансовой отчетности требует тщательного рассмотрения технологических, организационных и этических аспектов. Методология решает эти проблемы путем включения междисциплинарного подхода, обеспечивающего целостное понимание проблем и возможностей, связанных с внедрением искусственного интеллекта в финансовую отчетность.

Целью исследования является предоставление ценной информации как научным кругам, так и бизнесу и промышленности. Ожидаемый результат — это прочная теоретическая основа, которая не только разъясняет синергию между искусственным интеллектом и цифровой трансформацией, но и предоставляет практические рекомендации для организаций, стремящихся улучшить свои возможности принятия решений в области финансовой отчетности.

Это исследование направлено на преодоление разрыва между теоретическими достижениями и практическими выводами, тем самым раскрывая неиспользованную ценность для бизнеса, присущую интеграции принятия решений на основе искусственного интеллекта с цифровой трансформацией в системах финансовой отчетности.

4. Инструменты цифровой трансформации процесса принятия решений

Инструменты цифровой трансформации финансовой отчетности могут существенно поддержать процесс принятия решений внутри организаций, разрабатывая стратегии, устойчивые к различным экономическим условиям. Они играют решающую роль в поддержке процессов принятия решений в финансовой отчетности, предоставляя данные в реальном времени, расширенную аналитику, автоматизацию и функции совместной работы. Эти инструменты способствуют более информированному, стратегическому и основанному на данных принятию решений внутри организаций. Интеграция передовых технологий и цифровых инструментов в системы финансовой отчетности дает ряд преимуществ, которые расширяют возможности принятия решений. Лица, принимающие решения, могут получить доступ к актуальной информации о ключевых финансовых показателях, показателях эффективности и рыночных тенденциях, что позволяет принимать более информированные и своевременные решения [17,18].

Передовые инструменты аналитики и визуализации данных помогают преобразовать сложные финансовые данные в понятные визуальные представления. Это помогает лицам, принимающим решения, выявлять закономерности, тенденции и аномалии, облегчая принятие решений на основе данных. Цифровые инструменты часто включают в себя возможности прогнозирования и прогнозной аналитики. Анализируя исторические данные и выявляя закономерности, эти инструменты могут помочь лицам, принимающим решения, делать более точные прогнозы о будущих финансовых тенденциях и результатах. Включение алгоритмов искусственного интеллекта и машинного обучения (ML) расширяет возможности систем финансовой отчетности. Эти технологии могут предоставлять интеллектуальную информацию, выявлять возможности и поддерживать принятие решений путем анализа больших наборов данных и облегчения сотрудничества и общения между различными заинтересованными сторонами, участвующими в процессе принятия решений [14,15].

оценка потенциальных результатов различных решений в различных условиях. Это помогает принимать решения, которые являются более надежными и адаптируемыми к различным обстоятельствам.

4.1. Разработка нейронной сети для интеграции ИИ в процессы принятия решений

Разработка нейронной сети для интеграции ИИ в финансовую отчетность предполагает разработку модели, которая сможет анализировать и интерпретировать финансовые данные из балансовых отчетов. Выбор трехслойной нейронной сети для задач бухгалтерского учета и финансовой отчетности — это не неотъемлемое правило, а скорее широко используемая архитектура, доказавшая свою эффективность в различных приложениях. Трехуровневая архитектура относительно проста и ее легче интерпретировать, если сравнивать ее с более глубокими аналогами. Эта архитектура имеет меньше параметров и слоев, что якобы делает ее более управляемой. Однако это не должно затмевать тот факт, что даже трехслойная нейронная сеть может функционировать как сложный черный ящик. Присущие нелинейные преобразования и взаимодействие между слоями затрудняют расшифровку того, как конкретные входные данные преобразуются в выходные. В финансовой отчетности, где прозрачность и подотчетность имеют первостепенное значение, непрозрачная природа нейронных сетей, независимо от их глубины, может привести к серьезным проблемам с интерпретацией. Поскольку интерпретируемость часто имеет решающее значение, а заинтересованные стороны должны понимать результаты модели и доверять им, эта сложность является не просто теоретической проблемой, но и практической, которая влияет на доверие и надежность в реальных приложениях.

Трехслойные нейронные сети особенно эффективны благодаря своей способности аппроксимировать широкий спектр функций. Эта возможность коренится в теореме Колмогорова о суперпозиции, которая утверждает, что трехслойная нейронная сеть может представлять любую многомерную функцию, как непрерывную, так и разрывную. Это делает такие сети универсальными для различных приложений, включая системы финансовой отчетности, где решающее значение имеет фиксация сложных нелинейных взаимосвязей внутри данных [22,23]. Одним из основных преимуществ трехслойной нейронной сети является ее относительная простота и интерпретируемость по сравнению с более глубокими сетями. Хотя интерпретировать процесс принятия решений в очень глубоких нейронных сетях может быть непросто, трехслойные модели обеспечивают баланс, поскольку они достаточно сложны, чтобы фиксировать сложные закономерности, и при этом остаются простыми для анализа и отладки. Такая интерпретируемость особенно важна в финансовом контексте, где прозрачность и подотчетность имеют первостепенное значение [24,25].

Более простые модели также менее склонны к переобучению и могут быть более надежными, особенно при работе с ограниченными данными. Для многих задач бухгалтерского учета и финансовой отчетности умеренное количество скрытых слоев может эффективно фиксировать основные закономерности и взаимосвязи в данных.

Мы разработали математическую модель нейронной сети с 31 входным блоком, 16 скрытых блоков и 2 выходных блока следующим образом:

$x_1, x_2, \dots, x_{31}$, чтобы быть входными функциями

$h_1, h_2, \dots, h_{16}$ — блоки скрытого слоя

y_1, y_2 — единицы выходного слоя

Математическая модель нейронной сети может быть выражена следующим образом:
Вычисление скрытого слоя:

$$h_j = \text{ReLU} \quad i = 1 \dots 31 w_{ij}(1) x_i + b_j(1) \text{ для } j = 1, 2, \dots, 16$$

где $\text{ReLU}(a) = \max(0, a)$ — функция активации выпрямленной линейной единицы.

Вычисление выходного слоя:

$$y_k = \text{Softmax} \quad j = 1 \dots 16 w_{jk}(2) h_j + b_k(2) \text{ для } k = 1, 2$$

были

да

$$\text{Softmax}(a)_i = \frac{e^{a_i}}{\sum_j e^{a_j}} \quad j = \text{функция активации SoftMax.} \quad 1 \text{ ea}_i$$

~~Софтмакс() = — это функция активации SoftMax.~~

Параметры модели (веса и смещения) изучаются во время обучения. Параметры модели (веса и смещения) изучаются во время обучения.

процесс минимизации конкретной функции потерь, обычно связанный с текущей задачей процесс минимизации конкретной функции потерь, обычно связанной с текущей задачей (например, классификация или регрессия). Обучение включает в себя корректировку весов и отклонений (классификация или регрессия). Обучение включает в себя корректировку весов и смещений с использованием алгоритмов оптимизации, таких как стохастический градиентный спуск (SGD).

Модель обучается по значениям пратичного распространения для вычисления расстояния и расчета. Модель обучается путем потери, а затем использование обратного распространения ошибки для обновления параметров модели. Обучение на случайной выборке продолжается до тех пор, пока модель не сойдется или пока не пройдет заранее определенное количество эпох: дефиниция. После обучения пользователи могут использовать модель для прогнозирования новых данных . После обучения выходная информация о распределении членов семейства параметров в сети. Эта информация используется для автоматического роста слоев обучающей сети с использованием рекурсивной нейронной сети для динамического отчета- подход задачи структуры баланса к скрытому слою, задачи отчетности, подключение входного блока конечного агрегатора балансов финансовой системы, а также формирование отчетов. Корректировка может быть выполнена с помощью характеристик исходных данных и требований задачи. составлено с учетом

В финансовых условиях, где данные могут быть ограничены, а вычислительные ресурсы могут быть ограничены.

Богатными примерами являются задачи регуляризации в балансе между сложностью и эффективностью. С другой стороны, при глубоком обучении часто встречаются проблемы с взрывом градиента. Чрезвычайно эффективным обучением является обучение модели. Три — во время обучения, что затрудняет обнаружение проблем, не связанных с проблемами функционирования функций как функции, таких как сеть, менее (например, линейный или квадратичный), которые смягчают проблему исчезновения градиента [69].

Входной уровень должен быть предназначен для сбора соответствующей информации о балансе. Баланс может быть абстрактным, как в рисунке 3.1, либо более конкретным, как в рисунке 4.1. Каждый узел в слое соответствует определенному признаку или переменной баланса: собственные капиталы, имуществу, обязательствам, обязательствам, налогам, амортизации и т.д. В качестве артефакта можно использовать структуру баланса, являющуюся основой для построения математической модели взаимосвязи в финансовых данных. Эта информация может быть использована для формирования функции для прогнозирования финансового состояния и положения акционеров этого объекта. Хотя структура является основой для построения модели, для экономического субъекта, эффективность которой зависит от качества и актуальности предоставляемого учета. Необходимо убедиться, что выбранные функции во входном слое значимы и что имеется достаточно данных для эффективного обучения модели.




Рисунок 3. Трехслойная нейронная сеть для задач бухгалтерского учета и финансовой отчетности.

скрытый слой — это место, где не принято высказывать сложные представления, а скрытый слой — это место, где необходимо изложить свои входные. Попадая из входного слоя к скрытому слою, можно получить шаблоны из входных данных. Если цель экономического субъекта заключается в повышении стоимости бизнеса, имеет смысл соотнести скрытый слой с финансовым КПЭ. Финансовые КРП часто служат показателями эффективности, которые напрямую влияют на общий результат.

ценность и успех бизнеса. Скрытый уровень может научиться абстрагировать и комбинировать функции входного слоя для выявления закономерностей, связанных с успешными финансовыми результатами или увеличением ценности бизнеса. Выбор двух выходных слоев зависит от конкретных целей и того, как компания определяет и соотносит ценность бизнеса с точки зрения прибыльности или роста доходов. Точные ключевые показатели эффективности могут варьироваться в зависимости от отрасли, целей компании и характера бизнеса, в который интегрируется инструмент нейронной сети AI.

Одним из ключевых показателей успешного бизнеса является его способность генерировать растущий доход с течением времени. Первый уровень результатов может представлять прогнозируемый рост доходов. Затем нейронную сеть научат изучать закономерности во входных данных, которые коррелируют с более высоким доходом.

Математическая модель будет иметь два выходных узла, каждый из которых соответствует одному из этих результатов. Для двоичной классификации компания может использовать сигмовидную функцию активации на выходном слое, а для задач регрессии компания может использовать линейную активацию [17].

$$(1) Y1 = \sigma(H \cdot W1 (2) + b1 (2))$$

$$(2) Y2 = \sigma(H \cdot W2 (2) + b2 (2))$$

где σ — сигмовидная функция активации, а $Y1$ и $Y2$ представляют прогнозируемые значения роста доходов и прибыльности соответственно.

Третий выходной узел может быть включен, если экономический субъект может учитывать отрицательные финансовые ключевые показатели эффективности, которые он хочет минимизировать, например, эксплуатационные расходы или коэффициент расходов.

$$(3) Y3 = \sigma(H \cdot W3 (2) + b3 (2))$$

4.2. Использование инструментов искусственного интеллекта теории игр в процессе принятия решений

Теория игр является мощной силой в эпоху цифровизации [20] и искусственного интеллекта, поскольку она обеспечивает структурированный подход к принятию решений в сложных, динамичных и неопределенных средах. Это помогает лицам, принимающим решения, ориентироваться в стратегических взаимодействиях, эффективно распределять ресурсы и адаптироваться к быстро меняющемуся ландшафту технологий и бизнеса. Как мы упоминали ранее, мы призываем экономические субъекты применять теорию игр к своим бизнес-процессам, чтобы раскрыть ценность бизнеса посредством принятия решений на основе искусственного интеллекта и цифровой трансформации в системах финансовой отчетности, а также создать матрицу выигрышей, которая представляет взаимодействие между различными решениями, создателями или заинтересованными сторонами. В контексте нашего исследования к этим лицам, принимающим решения, могут относиться руководство компании, акционеры, система искусственного интеллекта и другие соответствующие организации.

Мы предполагаем, что есть два ключевых лица, принимающих решения: руководство компании (CM) и акционеры (SH), и для каждого из них есть два стратегических выбора: внедрить финансовую отчетность на основе искусственного интеллекта (AI) или придерживаться традиционной отчетности (TR). Выгоды выражаются в виде бизнес-ценности или полезности для каждой комбинации вариантов.

Объяснение выгод • Высокие,

высокие: если и руководство компании, и акционеры решат внедрить финансовую отчетность на основе искусственного интеллекта, они оба получат высокую ценность для бизнеса или полезность. • Низкая, высокая: если руководство компании выбирает ИИ, а акционеры придерживаются традиционной отчетности, руководство компании может получить низкую ценность (например, из-за затрат на внедрение), в то время как акционеры получат высокую ценность (поскольку они могут предпочесть знакомую традиционную отчетность). составление отчетов).

• Высокая, низкая: если руководство компании придерживается традиционной отчетности, в то время как акционеры предпочитают отчетность, основанную на искусственном интеллекте, руководство компании может достичь высокой ценности (поскольку они избегают затрат на внедрение), но акционеры получают низкую ценность (поскольку они желают воспользоваться преимуществами искусственного интеллекта). управляемая отчетность). • Средний, средний: если и руководство компании, и акционеры придерживаются традиционной отчетности, они оба достигают среднего уровня ценности или полезности.

Мы можем подробно рассказать о выгодах с точки зрения увеличения ценности как для руководства компании, так и для акционеров, основываясь на двух стратегических вариантах: внедрить финансовую отчетность на основе искусственного интеллекта или придерживаться традиционной отчетности. Значения представляют собой воспринимаемую ценность или полезность бизнеса, причем более высокие значения указывают на более высокую воспринимаемую ценность. Высокое, среднее и низкое являются качественными представлениями воспринимаемой ценности, а фактические числовые значения будут зависеть от конкретного контекста и предпочтений заинтересованных сторон.

Выгоды описаны в таблице 1, а фактические значения будут зависеть от таких факторов, как отрасль, конкретные цели и предпочтения заинтересованных сторон, а также предполагаемые преимущества и недостатки отчетности на основе ИИ по сравнению с традиционной отчетностью в данном контексте.

Эта матрица обеспечивает структурированный способ понять, как решения каждой стороны влияют на воспринимаемую ценность как для руководства компании, так и для акционеров:

Таблица 1. Матрица выигрышей.

Компания Управление	Акционеры		
	ИИ		ТР
	ИИ	Высоко высоко	Низкий высокий
	ТР	Высокая низкая	Средний, Средний

- **Высокий, высокий (ИИ):**

Управление компанией (CM): Высокая ценность, поскольку ожидается, что финансовая отчетность на основе ИИ повысит эффективность, точность и принятие стратегических решений, что приведет к повышению общей эффективности бизнеса.

Акционеры (SH): Высокая ценность, поскольку они получают выгоду от повышения прозрачности, более информированного принятия решений руководством и потенциального увеличения прибыли.
 - **Низкий, высокий (ТР): Управление компанией**

(CM): Низкая ценность, поскольку использование традиционной отчетности может привести к упущенным возможностям для повышения эффективности, стратегического понимания и экономии средств, предлагаемых отчетами на основе искусственного интеллекта.

Акционеры (SH): Высокая ценность, поскольку они могут предпочесть привычность и стабильность традиционной отчетности, потенциально воспринимая меньший риск или нарушение своих инвестиций.
 - **Высокий, низкий (ИИ):**

Управление компанией (CM): Высокая ценность, поскольку внедрение отчетности на основе ИИ отвечает цели руководства по внедрению инновационных технологий и поддержанию конкурентоспособности.

Акционеры (SH): Низкая стоимость, поскольку они могут быть разочарованы решением не придерживаться традиционной отчетности, потенциально воспринимая более высокие риски или неопределенности.
 - **Средний, Средний (ТР):**

Управление компанией (CM): среднее значение, поскольку использование традиционной отчетности может обеспечить стабильность, но не может использовать потенциальные преимущества, предлагаемые отчетностью на основе искусственного интеллекта.

Акционеры (SH): Средняя ценность, поскольку они сохраняют ощущение стабильности, но могут упустить потенциальные улучшения в принятии решений и эффективности.
- Финансовые директора сталкиваются как с проблемами, так и с возможностями в процессе принятия решений в области ИИ в конкретной отрасли и нормативной среде. Они могут варьироваться в зависимости от конкретных обстоятельств каждой организации. Им необходимо ориентироваться в сложных правилах конфиденциальности данных, чтобы гарантировать, что использование ИИ соответствует законам о конфиденциальности, особенно в отраслях, имеющих дело с конфиденциальной информацией клиентов. Еще одна задача, с которой вскоре столкнется руководство, — это не отставать от меняющихся правил, касающихся ИИ, и обеспечивать соответствие систем ИИ отраслевым законам и стандартам.

Матрицы теории игр можно адаптировать к различным сценариям принятия решений, и применительно к контексту принятия решений финансовыми директорами (CFO) в сфере ИИ мы предлагаем четыре матрицы, которые можно принять во внимание в процессе принятия решений. : Финансовые директора, принимающие решения, связанные с ИИ, могут использовать матрицы теории игр для навигации по четырем ключевым сценариям: раннее и позднее внедрение ИИ, разработка ИИ внешними поставщиками или собственными силами, сотрудничество в обмене данными и защита данных, а также упреждающее или реактивное соблюдение нормативных требований. , балансируя выгоды, затраты и риски для конкурентных преимуществ и инноваций.

4.3. Проблемы этики и конфиденциальности в финансовой отчетности, основанной на искусственном интеллекте

В этой относительно новой среде финансовой отчетности, основанной на искусственном интеллекте, вопросы конфиденциальности данных имеют первостепенное значение. Обширные требования к данным систем искусственного интеллекта часто включают конфиденциальную финансовую и личную информацию, что повышает риск несанкционированного доступа и утечки данных [27]. В основе нашей работы лежит целостность и конфиденциальность данных, с которыми мы работаем. Интегрируя ИИ, мы должны проявлять бдительность, защищая эти данные с помощью надежных методов шифрования, гарантируя, что конфиденциальная информация остается в безопасности как при передаче, так и при хранении. Заинтересованные стороны должны быть полностью информированы о том, как их данные собираются, хранятся и используются. Эта прозрачность распространяется на получение явного согласия от лиц, чьи данные используются. Внедряя строгие политики управления данными, мы можем определить четкий контроль доступа и гарантировать, что данные будут доступны только авторизованному персоналу при соответствующих обстоятельствах. Подотчетность и прозрачность в системах ИИ имеют решающее значение, и крайне важно, чтобы разработчики приложений создали четкие рамки подотчетности, определяющие обязанности пользователей ИИ, операторов и лиц, принимающих решения.

При возникновении ошибок должен существовать прозрачный процесс выявления и устранения источника проблемы. Внедрение объяснимых методов искусственного интеллекта может существенно помочь этому процессу. Эти методы позволяют нам понять и сформулировать, как системы ИИ принимают решения, тем самым способствуя доверию и подотчетности между заинтересованными сторонами [28].

С широким внедрением международных стандартов бухгалтерского учета соблюдение нормативных требований становится постоянной проблемой в нашей профессии. Приложения искусственного интеллекта в финансовой отчетности должны соответствовать множеству нормативных требований, от финансовых правил до законов о защите данных. Участие в постоянном диалоге с регулирующими органами может дать ценные рекомендации и помочь обеспечить соответствие наших систем искусственного интеллекта действующему законодательству. Регулярные проверки соответствия необходимы для проверки соблюдения требований и устранения любых пробелов в наших процессах.

Риски безопасности являются неотъемлемым аспектом интеграции ИИ в финансовую отчетность. Системы искусственного интеллекта могут стать объектом кибератак, что потенциально может привести к утечке данных или манипулированию финансовой информацией [29]. Чтобы снизить эти риски, мы должны реализовать передовые меры кибербезопасности и разработать комплексные планы реагирования на инциденты. Регулярные оценки безопасности помогут выявить и устранить уязвимости, гарантируя целостность и надежность наших систем искусственного интеллекта. В реальных ситуациях несколько передовых мер кибербезопасности доказали свою эффективность в защите систем финансовой отчетности, управляемых искусственным интеллектом, например, многофакторная аутентификация, которая значительно повышает безопасность, требуя от пользователей предоставления двух или более факторов проверки для получения доступа к системе. , сквозное шифрование, обеспечивающее шифрование данных с момента их создания до тех пор, пока они не будут получены и расшифрованы предполагаемым получателем, или проведение регулярных аудитов безопасности и тестов на проникновение , которые позволяют организациям активно выявлять и устранять уязвимости в своих системах [29].

5. Результаты и обсуждение.

Сочетание модели нейронной сети с теорией игр, представленной в матрице, может оказаться мощным подходом. Его часто называют теоретико-игровым машинным обучением и используют для поддержки принятия решений в компаниях. Нейронную сеть можно использовать для прогнозирования финансовых ключевых показателей эффективности или других соответствующих результатов, а матрица теории игр может помочь проанализировать стратегические взаимодействия между различными организациями или заинтересованными сторонами. Его цель — понять, как разные агенты или игроки, каждый из которых преследует свои собственные цели, принимают решения в конкурентной или конкурентной бо

атмосфера сотрудничества. Мы используем теорию игр как раздел математики и экономики, чтобы следить за взаимодействием между рациональными лицами, принимающими решения, часто упоминаемыми в литературе как игроки, в ситуациях, когда результат решения одного игрока зависит от решения других, и мы предлагаем объединить методы машинного обучения и интегрировать с помощью теории игр, чтобы моделировать и прогнозировать поведение игроков, которые могут получить выгоду от создание положительной стоимости бизнеса. В нашей теории игр игроки представляют акционеров и управленческой командой, а стратегии включают увеличение рыночной капитализации за счет увеличение доходов или прибыльности и выплат, представленных в матрице. Стратегии предложенные в исследовании, — это варианты выбора, доступные каждому игроку, такие как выбор цифровизация и внедрение технологий искусственного интеллекта или использование традиционных методов бухгалтерского учета. и отчетность, а выплаты представляют собой результаты, связанные с конкретными комбинациями стратегий, выбранных всеми игроками. Для применения стратегий используются прогнозные модели, такие как нейронные сети с древовидными слоями могут использоваться для оценки вероятных выборов или действий. игроков на основе исторических данных бухгалтерского учета, извлеченных из баланса и прибыли и данные о потерях или другие соответствующие функции.

Учитывая характеристики нашей нейронной сети и структуру платежной матрицы из теории игр мы предлагаем назвать теоретическую модель «Decision Harbour AI» именем что отражает интеграцию искусственного интеллекта, принятия финансовых решений и стратегического анализ и символизирует безопасную и информированную гавань для принятия решений с помощью искусственных интеллект. Теоретико-игровое машинное обучение обеспечивает основу для понимания и прогнозирование стратегических взаимодействий [30]. Интегрируя модели машинного обучения с концепции теории игр, мы предсказываем, что станет возможным получить представление о процессах принятия решений в сложных, динамичных средах. Этот подход может быть ценным для принятия обоснованных решений в конкурентных или совместных сценариях, где множество вовлечены заинтересованные стороны [31].

В нашем сценарии у нас есть матрица теории игр с двумя игроками: руководством компании и акционерами, и матрица представляет возможные результаты, основанные на решения, принимаемые этими игроками. Мы можем научить нейронную сеть прогнозировать финансовые Ключевые показатели эффективности или результаты, представляющие интерес, такие как рост доходов, прибыльность и эффективность затрат, как показано на рисунке 4. После того, как мы обучили нейронную сеть прогнозированию положительных показателей производительности, мы использовали обученную нейронную сеть для прогнозирования для каждого игрока (Компания Управление, ИИ и TR) на основе входных функций и KPI в скрытом слое.

Электроника 2024, 13, х НА ЭКСПЕРТИЗУ




Рисунок 4. Теоретическая модель ИИ Decision Harbor — сценарий 1.
Рисунок 4. Теоретическая модель ИИ Decision Harbor — сценарий 1.

В плохие финансовые годы распределение данных может измениться. Закономерности и взаимосвязи между входными функциями и финансовыми результатами могут измениться, что приведет к несоответствию между данными обучения и тестирования. Нейронной сети, обученной на исторических данных, может быть сложно обобщить эти новые условия. Прогнозирующая эффективность модели может ухудшиться в плохие финансовые годы, если закономерности, наблюдаемые во время обучения, больше не сохраняются. Модель может давать неточные прогнозы, особенно если она не встречала подобных сценариев в обучающих данных (рис. 5).

Рисунок 4. Теоретическая модель ИИ Decision Harbor — сценарий 1.

В плохие финансовые годы распределение данных может измениться. Закономерности и отношения входными параметрами и финансовыми результатами могут измениться, что приведет к несоответствию между соотношениями между входными функциями и финансовыми результатами могут измениться, что приведет к несоответствию между данными обучения и тестирования. Нейронная сеть, обученная на исторических данных, может столкнуться с трудностями при обобщении этих новых условий. Прогнозирующая эффективность модели может быть снижена в плохие финансовые годы, если закономерности, наблюдаемые во время обучения, больше не сохраняются. Модель может давать неточные прогнозы, особенно если не сталкивалась с подобными в обучающих данных (рис. 5).




Рисунок 5. Теоретическая модель ИИ Decision Harbor — сценарий 2.

Мы предлагаем, чтобы компания реализовала стратегию непрерывного обучения моделей. Мы предлагаем, чтобы компания реализовала стратегию непрерывного обучения моделей, чтобы адаптироваться к меняющимся финансовым условиям. Модель должна регулярно обновляться с учетом меняющихся финансовых условий. Модель должна регулярно обновляться новыми данными, особенно в периоды финансовой нестабильности, чтобы гарантировать их актуальность. Данные, особенно в периоды финансовой нестабильности, чтобы гарантировать их актуальность. Для того чтобы модель привела к принятию правильных финансовых решений, руководство должно разработать сценарии. Для оценки эффективности модели в различных финансовых условиях. Этот анализ предназначен для тестирования модели на смоделированных сценариях, представляющих различные экологические экономические состояния, включая хорошие и плохие финансовые годы. Если нейронная сеть работает хорошо, хорошие финансовые годы, это обеспечивает подтверждение надежности модели. Это предполагает, что модель может адаптироваться к различным финансовым условиям и продолжает обеспечивать точную прогнозы, когда условия благоприятны. Хорошие финансовые годы могут положительно укрепить использование модели для принятия решений. Достоверные прогнозы в нашей компании во время эти периоды могут способствовать эффективному стратегическому планированию, распределению ресурсов и другим решения, повышающие ценность бизнеса. Лица, принимающие решения, могут обрести большую уверенность в прогнозах модели в хорошие финансовые годы. Эта уверенность может привести к большему опора на модель для принятия решений.

Цикл Деминга (PDCA) можно использовать как итеративный четырехэтапный метод управления для постоянного улучшения. Применение цикла PDCA к непрерывному обучению и сценарный анализ нашей модели нейронной сети в контексте меняющихся финансовых условий это разумный и эффективный подход. Мы должны контролировать процесс обучения и оценивать улучшится ли производительность модели или останется стабильной, выполните анализ сценария используя подготовленные сценарии или инструменты моделирования, и оцените точность, чувствительность модели, и специфичность различных сценариев для выявления любых закономерностей низкой производительности. или переоснащение.

Если сценарный анализ нашей нейронной сети выявит недостатки, мы должны рассмотреть корректировка модели или процесса генерации сценария. Это может включать переопределение функций, введение новых функций или изменение подхода к моделированию. Теоретический

Модель может включать в себя любые необходимые улучшения для повышения способности модели справляться с различными финансовыми условиями. Мы можем применить стресс-тестирование к нашей модели [23], подобно тому, как банки проводят стресс-тесты для оценки устойчивости своих финансовых систем в неблагоприятных условиях. В контексте нашей модели нейронной сети и матрицы теории игр стресс-тестирование может помочь нам понять, насколько хорошо работает модель и насколько надежным является принятие решений перед лицом экстремальных или неожиданных финансовых сценариев. Глубокое обучение может быть применено к входному слою в нашей сети в контексте стресс-тестирования динамического баланса [31,32]. Если балансовый отчет, который генерирует финансовую информацию для данных входного слоя, имеет временное измерение, например ежеквартальное или годовое, мы можем рассмотреть рекуррентные нейронные сети или сети долгосрочной краткосрочной памяти (LSTM) для фиксации временных закономерностей и зависимостей в данных. Если наши входные данные включают в себя различные источники, такие как финансовая отчетность, рыночные данные и экономические показатели, мы предлагаем применять архитектуры, поддерживающие мультимодальную интеграцию данных. Это позволяет модели одновременно учиться на разных типах информации. В целом, важно адаптировать подход глубокого обучения к конкретным требованиям и характеристикам наших финансовых данных и целям стресс-тестирования. Наша теоретическая модель DecisionHarborAI также может быть реализована в государственных организациях. Применение инструментов ИИ, таких как эта теоретическая двухуровневая модель, в государственном секторе может принести значительные выгоды, такие как помощь в анализе воздействия различных политик, помощь политикам в понимании потенциальных результатов и принятии обоснованных решений, предоставление информации об оптимизации распределения ресурсов для достижения желаемых результатов, оценка эффективности государственных программ и инициатив, а также повышение участия граждан путем предоставления основанной на данных информации о процессах принятия решений, содействия прозрачности и доверию между общественностью и правительством [33].

Для эффективной реализации такой модели возникает несколько практических рекомендаций. Регулярные обновления и переподготовка нейронной сети новыми данными имеют решающее значение для поддержания точности и актуальности.

Первым шагом является предоставление изображения или PDF-файла баланса в наш API. Это будет проводиться в мобильном приложении или веб-приложении. Как только изображение или PDF-файл получено, оно преобразуется в файл TXT. Анализатор берет TXT, полученный в результате OCR, и преобразует его в структурированный JSON с помощью машинного обучения. Затем JSON возвращается как выходные данные API. Отсюда данные баланса можно обрабатывать дальше. Затем полный набор данных используется для обучения нейронной сети, способной прогнозировать ключевые показатели финансовой деятельности, такие как рост доходов, прибыльность и эффективность затрат. Модель DecisionHarborAI идет еще дальше, включив в нее структуру теории игр. Это позволяет провести детальный анализ стратегического взаимодействия между заинтересованными сторонами, такими как руководство и акционеры. Понимая эту динамику, организация может согласовывать свои стратегические решения с интересами всех вовлеченных сторон, тем самым максимизируя ценность бизнеса.

Для обеспечения надежности проводится непрерывный анализ сценариев и стресс-тестирование. Эта практика не только подтверждает предсказания модели в различных условиях, но и готовит институт к возможным экономическим колебаниям. Результаты весьма значительны: расширенные возможности принятия решений, значительный рост эффективности за счет автоматизации и стратегическое согласование, которое способствует общей эффективности бизнеса.

Ограничения также необходимо учитывать при внедрении моделей финансовой отчетности на основе искусственного интеллекта, таких как DecisionHarborAI. Одним из наиболее существенных ограничений является качество данных, поступающих в модели ИИ. Для оптимального функционирования системам искусственного интеллекта требуются огромные объемы высококачественных данных. Однако финансовые данные часто могут быть неполными, противоречивыми или зашумленными. Неточные или некачественные данные могут привести к ошибочным прогнозам и ошибочным процессам принятия решений. Организации должны вкладывать значительные усилия в очистку и проверку данных, чтобы гарантировать, что данные, используемые для обучения и оперативных целей, являются точными и надежными. Это может быть ресурсоемким и не всегда осуществимым, особенно для небольших учреждений с ограниченным бюджетом. Как и все модели ИИ, DecisionHarborAI будет обучаться на исторических данных и может хорошо работать в условиях, аналогичных тем, которые присутствуют в наборе обучающих данных. Способность нашей теоретической модели адаптироваться к экономическим изменениям

регуляторные изменения и непредвиденные глобальные события, такие как финансовые кризисы или пандемии, являются серьезной проблемой [34]. Модель DecisionHarborAI может оказаться неспособной эффективно обобщить новые, ранее невиданные сценарии, что приведет к снижению производительности. Чтобы гарантировать, что DecisionHarborAI остается актуальным и точным, потребуется постоянное переобучение и проверка моделей, но управлять этим может быть сложно и требует постоянных инвестиций.

6. Выводы

При внедрении нейронной сети для финансового учета важно учитывать такие факторы, как качество данных, интерпретируемость модели и конкретную нормативную среду. Модель, предлагаемая в этом исследовании, предлагает интегрированный подход к поддержке принятия решений, сочетая прогнозирующие возможности нейронных сетей со стратегическими знаниями, предоставляемыми теорией игр. Эта интеграция направлена на улучшение процессов принятия решений в сложных и динамичных средах и смещает фокус модели на прогнозирование финансовых показателей и поддержку принятия финансовых решений. Компонент нейронной сети нового инструмента искусственного интеллекта предназначен для предоставления финансовых прогнозов и анализа на основе исторических данных. Это включает в себя прогнозирование ключевых финансовых показателей, таких как рост доходов, рентабельность и эффективность затрат. Нейронные сети могут быть ценным инструментом для калибровки результатов в среде финансового учета и продемонстрировали эффективность при обработке сложных финансовых данных, выявлении закономерностей и составлении прогнозов. Включение матрицы выигрышей теории игр в этот новый инструмент принятия решений ИИ представляет стратегическую основу для анализа взаимодействия между лицами, принимающими решения. Это позволяет рассматривать стратегический выбор и результаты в более динамичном и конкурентном контексте. Инструменты цифровой трансформации искусственного интеллекта могут значительно улучшить процессы принятия финансовых решений и общее стратегическое управление. Эти инструменты могут помочь организациям использовать аналитику, основанную на данных, и автоматизировать рутинные задачи, потенциально повышая эффективность и точность решений. Однако важно признать, что технологии искусственного интеллекта также имеют проблемы и недостатки, такие как проблемы конфиденциальности данных, риск алгоритмических ошибок и потребность в значительных вычислительных ресурсах. Кроме того, сложность моделей ИИ может затруднить их интерпретацию и доверие, что может ограничить их практическое применение в определенных контекстах. Поэтому, хотя ИИ предлагает многообещающие достижения, важно подходить к его интеграции со сбалансированной точки зрения, признавая как его преимущества, так и его ограничения. Все будущие инструменты помощи в принятии решений должны постоянно изучать и обновлять свои прогнозы, обеспечивая актуальность и точность с течением времени. Модель, предлагаемая в этой статье, должна быть оснащена способностью подвергаться стресс-тестированию и сценарному анализу, что позволит ей оценить ее эффективность в различных финансовых условиях, включая как благоприятные, так и неблагоприятные сценарии, что будет способствовать ее надежности.

Объединение матрицы выплат нейронных сетей представляет собой комплексный и адаптивный инструмент поддержки принятия решений, который использует сильные стороны нейронных сетей и теории игр для предоставления ценной информации для принятия финансовых решений как в частном, так и в государственном секторах и обеспечивает ощутимую ценность для бизнеса. Непрерывное обучение, анализ сценариев и стратегические рамки способствуют его потенциальной эффективности в динамичных и неопределенных условиях. Концепция интеграции принятия решений на основе искусственного интеллекта непосредственно отражена в выводах этой статьи. Смешанные цифровые инструменты сочетают в себе прогнозирующие возможности нейронных сетей со структурой теории игр, подчеркивая интеграцию передовых методов искусственного интеллекта для более обоснованного принятия решений. Успех модели будет зависеть от тщательного тестирования, сотрудничества с экспертами в предметной области и постоянных доработок на основе отзывов из реального мира.

Инструменты цифровой трансформации могут существенно помочь процессу принятия финансовых решений и общему стратегическому управлению в компании, анализируя исторические финансовые данные и делая точные прогнозы о будущих тенденциях и результатах. Эти инструменты позволяют оценивать и прогнозировать потенциальные риски путем анализа различных источников данных. Это позволяет организациям заранее выявлять и снижать риски при принятии финансовых решений, а также автоматизировать повторяющиеся и рутинные задачи, такие как ввод данных, сверка и отчетность.

[illegible]

Рекомендации

1. Имониана, Дж.О.; Реджинато, Л.; Младший, ЕВС; Бенетти, К. Мнения заинтересованных сторон о принятии международных стандартов финансовой отчетности малыми и средними предприятиями: многомерный анализ. Межд. Дж. Бус. Экстрен. Отметка. 2025, 1. [\[Перекрестная ссылка\]](#)

2. Радичич, Д.; Петкович, С. Влияние цифровизации на технологические инновации на малых и средних предприятиях (МСП). Технол. Прогноз. Соц. Чанг. 2023, 191, 122474. [\[CrossRef\]](#)

3. Саура, младший; Рибейро-Сориано, Д.; Паласиос-Маркес, Д. Оценка проблем конфиденциальности в области поведенческой науки о данных в искусственном правительстве развертывание разведки. Правительственная инф. Q. 2022, 39, 101679. [\[CrossRef\]](#)

4. Фачча, А.; Аль-Накби, МЫК; Lootah, SA Интегрированный цикл облачного финансового учета. В материалах 3-й Международной конференции по облачным вычислениям и вычислениям с большими данными 2019 г., Оксфорд, Великобритания, 28–30 августа 2019 г.; АСМ: Нью-Йорк, штат Нью-Йорк, США, 2019 г.; стр. 31–37. [\[Перекрестная ссылка\]](#)

5. Аллам, К.; Родвал, А. Аналитика больших данных на основе искусственного интеллекта: раскрытие идей для развития бизнеса. EPH-Int. Дж. Наук. англ. 2023, 9, 53–58. [\[Перекрестная ссылка\]](#)

6. Менгу, Д.; Луо, Ю.; Ривенсон, Ю.; Озкан, А. Анализ дифракционных оптических нейронных сетей и их интеграция с электроникой Нейронные сети. IEEE Дж. Сел. Вершина. Квантовый электрон. 2020, 26, 1–14. [\[Перекрестная ссылка\]](#)

7. Шенгелия, НСН; Циклаури, ЭТЗ; Жепка, АРА; Шенгелия, РСР Влияние финансовых технологий на цифровую трансформацию развитие бухгалтерского учета, аудита и финансовой отчетности. Экономика 2022, 105, 385–399. [\[Перекрестная ссылка\]](#)

8. Пакурари, Д.; Нечита, Э. Некоторые соображения по облачному учету. В исследованиях и научных исследованиях. Экономическое издание; Факультет экономических наук, Университет Василе Александри, Бакзу: Бакзу, Румыния, 2013 г. [\[CrossRef\]](#)

9. Ли, М.; Ю, Ю.; Ли, Х.; Чжао, JL; Чжао, Д. Факторы, определяющие трансформацию МСП в сторону облачных услуг: перспективы экономической и социальной рациональности. Пак. Азия Дж. Доц. Инф. Сист. 2019, 11, 65–87. [\[Перекрестная ссылка\]](#)

10. Соренсен, М.; Ясуда, А. Влияние прямых инвестиций на заинтересованных лиц. В Справочнике по экономике корпоративных финансов: прямые инвестиции и предпринимательские финансы; Elsevier: Амстердам, Нидерланды, 2023 г.; стр. 299–341. [\[Перекрестная ссылка\]](#)

11. Наик Н.; Хамид, БЗ; Шетти, ДК; Суэйн, Д.; Шах, М.; Пол, Р.; Аггарвал, К.; Ибрагим, С.; Патил, В.; Смити, К.; и другие. Правовые и этические аспекты использования искусственного интеллекта в здравоохранении: кто несет ответственность? Передний. Хирург. 2022, 9, 862322. [\[CrossRef\]](#)

12. Во-Тхань, Т.; Заман, М.; Хасан, Р.; Актер, С.; Данг-Ван, Т. Цифровизация услуг в ресторанах высокой кухни: экономия и выгода перспектива. Межд. Дж. Созерцание. Хосп. Менеджер. 2022, 34, 3502–3524. [\[Перекрестная ссылка\]](#)

13. Агустин-Хуан, И.; Гласс, Дж.; Павар, В. Сбалансированная система показателей для оценки автоматизации в строительстве. В материалах конференции Creative Construction 2019, Будапешт, Венгрия, 29 июня – 2 июля 2019 г.; Будапештский университет технологии и экономики: Будапешт, Венгрия, 2019 г.; стр. 155–163. [\[Перекрестная ссылка\]](#)

14. Ван З.; Ван, К.; Не, З.; Ли, Б. Прогнозирование финансовых затруднений корпораций на основе залога акций контролирующего акционера. Прил. Экон. Летт. 2022, 29, 1365–1368. [\[Перекрестная ссылка\]](#)

15. Ду, Г.; Элстон, Ф. ОТЗЫВАННАЯ СТАТЬЯ: Оценка финансовых рисков для повышения точности финансового прогнозирования в интернет- финансовой индустрии с использованием моделей анализа данных. Опер. Менеджер. Рез. 2022, 15, 925–940. [\[Перекрестная ссылка\]](#)

16. Сонг, З.; Ву, С. Пост, теория игр и принятие решений в области финансового прогнозирования. Финанс. Рез. Летт. 2023, 58, 104288. [\[CrossRef\]](#)

17. Мурали, М.; Канмани, С. Моделирование приложений теории игр с использованием сетевых элементов для обеспечения равновесия Нэша через цену. Анархия и цена стабильности. Межд. Дж. Сист. Сист. англ. 2024, 14. [\[CrossRef\]](#)

18. Хамидоглу, А. Теоретико-игровой подход к построению новой модели цепочки поставок агропродовольственной продукции, поддерживаемой правительством . Эксперт. Сист. Прил. 2024, 237, 121353. [\[CrossRef\]](#)

19. Чжуан, Ю.Т.; Ву, Ф.; Чен, К.; Пан, Ю.Х. Проблемы и возможности: от больших данных к знаниям в области искусственного интеллекта 2.0. Передний. Инф. Технол. Электрон. англ. 2017, 18, 3–14. [\[Перекрестная ссылка\]](#)

20. Махмуд А.; Аль Марзуки, А.; Эль Хатиб, М.; АлАмими, Х. Как искусственный интеллект может использовать информационную систему управления проектами (PMIS) и принятие решений на основе данных в управлении проектами. Межд. Дж. Бус. Анальный. Безопасность. (IJBAS) 2023, 3, 184–195. [\[Перекрестная ссылка\]](#)

21. Чонгкс, Дж.; Катиараян, В.; Чонг, Дж.; Син, К. Роль искусственного интеллекта в возможностях, проблемах и последствиях принятия стратегических решений для менеджеров в эпоху цифровых технологий. Межд. Дж. Манаг. Коммерческий. Иннов. 2023, 11, 73–79.

22. Лачкович М. Теорема суперпозиции колмогоровского типа для ограниченных непрерывных функций. Дж. Прибл. Теория 2021, 269, 105609. [\[Перекрестная ссылка\]](#)

23. Курайси А. Нормальность данных с использованием критериев Колмогорова-Смирнова и Шапиро-Уилка. J-NEST J. Образование в области здравоохранения. Экон. наук. Технол. 2020, 3, 7–11. [\[Перекрестная ссылка\]](#)

24. Шмидт-Хибер Дж. Еще раз о теореме о представлении Колмогорова-Арнольда. Нейронная сеть. 2021, 137, 119–126. [\[Перекрестная ссылка\]](#)

25. Исмаилов В.Е. Трехслойная нейронная сеть может представлять любую многомерную функцию. Дж. Математика. Анальный. Прил. 2023, 523, 127096. [\[Перекрестная ссылка\]](#)

26. Элахи, М.; Афоляррами, Южная Каролина; Ластра, JLM; Гарсия, JAP. Комплексный обзор литературы по применению методов искусственного интеллекта. на протяжении всего жизненного цикла промышленного оборудования. Дисков. Артиф. Интел. 2023, 3, 43. [\[CrossRef\]](#)

27. Хаббал А.; Али, МК; Абузараида, магистр искусственного интеллекта, управление доверием, рисками и безопасностью (AI TRISM): структуры, приложения, проблемы и будущее направления исследований. Эксперт. Сист. Прил. 2024, 240, 122442. [\[CrossRef\]](#)

28. Ченг, Л.; Лю, Х. От принципов к практике: интертекстуальное взаимодействие между этическими и правовыми дискурсами ИИ. Межд. Дж. Лег. Дискурс 2023, 8, 31–52. [\[Перекрестная ссылка\]](#)

-
29. Хамфрис, Д.; Коай, А.; Десмонд, Д.; Мили, Э. Реклама искусственного интеллекта как угроза кибербезопасности: моральная ответственность за внедрение генеративный ИИ в бизнесе. *Этика ИИ* 2024. [\[CrossRef\]](#)
30. Чо, С.; Васархели, Массачусетс; Сан, Т.; Чжан, К. Обучение машинному обучению в бухгалтерском учете и страховании. *Дж. Эмерг. Технол. Счет.* 2020, 17, 1–10. [\[Перекрестная ссылка\]](#)
31. Ганайе, Массачусетс; Ху, М.; Малик, АК; Танвир, М.; Сугантан, П.Н. Ансамблевое глубокое обучение: обзор. *англ. Прил. Артиф. Интел.* 2022, 115, 105151. [\[CrossRef\]](#)
32. Чжан Э.; Кюи, П.; Чжу, В. Глубокое обучение на графиках: обзор. *IEEE Транс. Знать. Данные англ.* 2022, 34, 249–270. [\[Перекрестная ссылка\]](#)
33. Чандана Чаритха, П.; Хемараджу, Б. Влияние искусственного интеллекта на принятие решений в организациях. *Межд. Дж. Мультидисциплин. Рез.* 2023, 5. [\[CrossRef\]](#)
34. Алдосери, А.; Аль-Халифа, КНЦ; Хамуда, А.М. Переосмысление стратегии обработки данных и интеграция для искусственного интеллекта: концепции, Возможности и вызовы. *Прил. наук.* 2023, 13, 7082. [\[CrossRef\]](#)

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.



Статья

Учимся повышать операционную эффективность за счет ошибок в позах
Оценка роботизированного опыленияЦзиньлун Чен¹, Цзюнь Сюэ^{1,*}, Миньао Ян² и Ханг Пан³¹ Школа компьютерных наук и информационной безопасности, Гуилиньский университет электроники и технологий, Гуилинь 541000, Китай;² 7259@guet.edu.cn Исследовательский центр искусственного интеллекта (BII), Институт автоматизации Китайской академии наук (CASIA), Пекин 100190, Китай;³ mhyang@nlpr.ia.ac.cn Факультет компьютерных наук Университета Чанчжи, Чанчжи 046011, Китай; panhang@ccz.edu.cn

* Переписка: 22032303110@mails.guet.edu.cn.

Аннотация : В последние годы широко обсуждаются автономные роботы-опылители. Однако точная оценка позы цветов в сложных сельскохозяйственных условиях остается сложной задачей. С этой целью в данной работе предлагается реализация архитектуры на основе трансформатора для изучения поступательных и вращательных ошибок между конечным фактором робота-опылителя и целевым объектом с целью повышения эффективности опыления робота в задачах скрещивания. Вклад заключается в следующем: (1) Мы разработали модель архитектуры трансформатора, оснащённую двумя нейронными сетями для распространения, которые напрямую регрессируют поступательные и вращательные ошибки между конечным фактором робота и целью опыления. (2) Кроме того, мы разработали функцию регрессионных потерь, которая учитывает поступательные и вращательные ошибки между конечным фактором робота и целью опыления. Это позволяет манипулятору робота быстро и точно идентифицировать цель опыления из текущего положения. (3) Кроме того, мы разработали стратегию, позволяющую легко получить значительное количество обучающих выборок в результате очного наблюдения, которые можно использовать в качестве входных данных для модели. Между тем, поступательные и вращательные ошибки, выраженные в декартовой системе координат конечного манипулятора, одновременно обозначаются как цели потерь. Это помогает оптимизировать обучение модели. Мы провели эксперименты на реалистичной роботизированной системе опыления. Результаты показывают, что предлагаемый метод превосходит современный метод как по точности, так и по эффективности.

Ключевые слова: робот-опылитель; трансформатор; ошибки смещения



Цитирование: Чен Дж; Сюэ Дж; Ян М;

Пан Х. Учимся совершенствоваться

Операционная эффективность из позы

Оценка ошибок в робототехнике

Опыление. Электроника 2024, 13, 3070.

<https://doi.org/10.3390/electronics13153070>

Академический редактор: Да-Дже Ли

Поступила: 24 июня 2024 г.

Пересмотрено: 26 июля 2024 г.

Принято: 1 августа 2024 г.

Опубликовано: 2 августа 2024 г.



Копирайт: © 2024 авторов.

Лицензия 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

Опыление с помощью роботов является темой уже более десяти лет [1]. Оно становится все более важным фактором растениеводства в сельскохозяйственной отрасли и предлагает решения насущных проблем, таких как сокращение числа естественных опылителей.

Роботы-опылители подразделяются на несколько типов для удовлетворения разнообразных потребностей сельскохозяйственного производства.

Автономные роботы, оснащенные передовыми зрением и искусственным интеллектом, самостоятельно перемещаются и опыляют. Дистанционно управляемые или полуавтономные роботы требуют контроля со стороны человека и подходят для сложных условий. Беспилотные летательные аппараты (БПЛА) эффективно опыляют большие поля сверху. Эти роботизированные системы созданы для имитации процесса опыления, традиционно выполняемого пчелами и другими насекомыми. Используя современные датчики, системы технического зрения и прецизионные манипуляторы роботы-опылители идентифицируют цветы и взаимодействуют с ними, откладывая пыльцу с высокой точностью и постоянством.

Обсуждались различные исследования в области автоматизированного опыления с применением опыления киви [2,3], цветков ежевики [4], ванили [5] и цветков томатов [6]. Техника опыления предполагает физический перенос пыльцы с мужских на пестики (репродуктивные органы женских цветков) [7]. Чтобы минимизировать потери пыльцы и обеспечить точный перенос на рыльца, необходимо устранить трудности

сбора пыльцыи проблемы поддержания ее активности [8]. К сожалению, это требует значительных затрат времени и усилий, что не учитывается должным образом в существующих подходах к опылению. Трудности возникают из-за очень маленького размера пестиков, а также из-за сложности точного определения их вращения и ориентации.

С этой целью в данной работе предлагается методология, основанная на архитектуре трансформатора, целью которой является повышение операционной эффективности роботизированного опыления в задачах скрещивания. Выходной слой модели включает в себя две отдельные нейронные сети прямого распространения, каждая из которых предназначена для регрессии поступательных и вращательных несоответствий между роботом и целью опыления соответственно. В отличие от традиционных функций потерь трансформатора, мы разработали новую функцию потерь, которая учитывает поступательные и вращательные несоответствия между конечным эффектом робота и целевыми опыления. Это позволяет манипулятору робота быстро и точно идентифицировать цель опыления на основе текущего обзора наблюдения. Тем временем мы также разработали стратегию сбора крупномасштабных обучающих выборок на основе наблюдения «глаз в руке» и обозначения ошибок поступательного движения и вращения, выявленных в декартовой системе координат конечного манипулятора, в качестве целевых потерь. Наблюдаемые изображения в текущей и целевой позициях в сочетании с поступательными и вращательными ошибками между ними обеспечивают большой масштаб для обучающих данных, тем самым улучшая обучение модели. На рисунке 1 показан робот-опылитель, использованный в этой работе.

Оставшаяся часть этой работы организована следующим образом: соответствующие работы изложены в Разделе 2; подробное описание метода представлено в разделе 3; В разделах 4–6 представлены эксперименты, обсуждение и выводы соответственно.




Рисунок 1. Робот-опылитель в основном состоит из роботизированной руки UR5 и монокулярной RGB-камеры, сконфигурированной по схеме «глаз в руке». На конце роботизированной руки имеется кисть для опыления пестиков. На иллюстрации изображена роботизированная рука, участвующая в опылении, где «ошибка смещения», отмеченная красным, представляет собой контент, который модель должна изучить. Здесь T_x , T_y и T_z обозначают компоненты поступательной ошибки вдоль осей X, Y и Z соответственно, а W_x , W_y и W_z представляют собой компоненты вектора вращения, обозначающие ошибки вращения.

2. Сопутствующая работа

2.1. Оценка позы

Достижение высокой точности конечного эффекта роботизированной руки представляет собой серьезную проблему. Для повышения точности положения конечного эффекта часто используются дополнительные датчики, такие как LiDAR или датчики давления, что может увеличить затраты. Некоторые методы основаны на оценке позы шестимерного объекта, построении шаблонов для сканирования различных позиций в каждом изображении, расчете оценок сходства в каждой позиции и получении наилучшего соответствия путем сравнения оценок сходства [9,10]. Другие используют методы, основанные на признаках, где модели CNN напрямую регрессируют трехмерные координаты каждого пикселя [11] или описывают апостериорную плотность позы конкретного объекта через CNN, сравнивая наблюдаемое изображение с визуализированным изображением [12]. Кроме того, некоторые методы сочетают в себе преимущества подходов на основе шаблонов и функций в рамках глубокого обучения. Сеть объединяет маркировку на уровне пикселей снизу вверх с регрессией положения объекта сверху вниз, что

трех мерное положение и трех мерное вращение объекта отдельно [13]. Все эти методы неизменно используют датчики глубины для сбора информации о глубине целевого объекта. Однако в сценариях, где информация о глубине не может быть получена, например, в сельском хозяйстве в роботизированном опылителе, обсуждаемом в этой статье, польза области цветков-опылителей приводит к плохому получению информации о глубине. Более того, обученные модели, включающие информацию о глубине [11–13], не выполняют прямую регрессию и не предсказывают трехмерную информацию о местоположении целевого объекта. В вышеупомянутые модели на основе шаблонов и объектов обучаются на облаках точек, но они по-прежнему сталкиваются с проблемами при обработке невыпуклых многогранников и данных, не являющихся многообразиями. Существующие методы обучения облакам точек в первую очередь подходят для правильных форм, таких как выпуклые многогранники и многообразия. Эти методы ограничены при работе со сложными и неправильными формами цветов в сельском хозяйстве в условиях, которые часто представляют собой неполиэдрические и немногочисленные структуры. Это ограничивает прямое применение традиционных методов обучения с использованием облака точек. Кроме того, существует несоответствие между обучением облака точек в виртуальных средах и реальными приложениями, что может повлиять на производительность модели.

В отличие от методов оценки позы, представленных ранее, которые полагаются на дополнительные датчики для захвата данных изображения с увеличенной глубиной для построения обучения облака точек — практика, которую трудно реализовать в невыпуклых и немногочисленных сельском хозяйстве в условиях — наш метод использует только обычные камеры для получения изображений RGB от конечного эффектора робота-опылителя. Этот подход обеспечивает бесшовное сквозное обучение в реальных условиях, тем самым устраняя несоответствия, обычно встречающиеся между обучением с помощью облака точек в виртуальных средах и их практическим применением в полевых условиях.

2.2. Традиционные методы и методы глубокого обучения для повышения

точности. Чтобы повысить точность конечного эффектора опыления, можно реализовать традиционные методы посредством конструкции роботизированной руки. Например, компания IIC разработала роботизированную руку для опыления киви [14], добившись высокой точности за счет выражения скорости конечного эффектора и углов скорости суставов через матрицу Якобиана. При планировании траектории интерполяция полиномом пятой степени обеспечивает непрерывность и плавность кривых скорости и ускорения каждого сустава. Для анализа моделирования используются прямая кинематика и методы Монте-Карло, чтобы охватить всю область опыления конечным эффектором. В системе технического зрения используется бинокулярная камера [15] для получения 3D-координат цветов в реальном времени, в сочетании с системой управления планированием траектории и расчетом точек интерполяции, для точного управления каждым суставным двигателем достижения двух точечного движения. Точное опыление. Однако та роботизированная рука использует бинокулярные камеры для получения трехмерных координат цветов, а сильный свет или окклюзии могут повлиять на точность системы зрения.

Традиционные алгоритмы все еще могут достигать определенных эффекторов в конкретных областях сельского хозяйства опыления. Недавнее исследование Н. Дык Тай [16] включало использование методов сегментации для обнаружения и сегментирования цветков дыни, использование математических моделей, основанных на биологических характеристиках цветков дыни, для определения ключевых точек направления роста каждого цветка, а также использование обратной проекции. Метод преобразования положения цветка из 2D-изображения в 3D-пространство, тем самым обеспечивая локализацию позы цветка.

В последние годы благодаря развитию и применению глубокого обучения, робот-опылитель STRADER J BrambleBee [4] объединил традиционные алгоритмы и алгоритмы глубокого обучения для оценки позы цветов. Система использует двухэтапную систему обработки изображений для распознавания цветов и оценки их позы. Сначала она использует алгоритм сегментации на уровне пикселей Наивного Байеса, затем использует сверточную нейронную сеть для классификации и уточнения позы, обеспечивая точность результатов распознавания. Наконец, карта прелестивий на основе октодерев и графов коэффициентов представляют собой карту цветов, отображая цветы и их положения в 3D для оптимизации оценки позы. Автоматический робот для опыления цветов арбуза Хубайба Ахмада [17] использует глубокое обучение для обнаружения двумерной информации о цветах и объединяет ее с традиционными алгоритмами для расчета глубины расположения цветов, тем самым достигая локализации цветов. Затем робот регулирует механическую руку, используя сервопривод, пока она не достигнет идеального положения опыления.

Сервоавтоматический робот-опылитель компании YANG [18] использует более совершенные алгоритмы обнаружения целей, такие как YOLOv5, YOLACT++ [19] и DETR [20], для обнаружения цветов, определения положения и ориентации пестика посредством вращения. Технология обнаружения объектов. Затем система использует стратегию псевдобининга, вычисляя трехмерные координаты пестика путем перемещения положения камеры и используя калибровку глаз-рука для преобразования этих координат в оперативную систему координат манипулятора робота. Вовремя задачи опыления система сочетает стратегии визуального сервоуправления, выполняющего грубое позиционирование, перемещая концевой эффектор рядом с цветком, с последующим точным позиционированием с использованием круговой траектории поиска, чтобы обеспечить точный контакт между щеткой для пыльцы и пестиком. Однако система по-прежнему имеет погрешность точности концевой эффектора 15 мм. Хотя круговая траектория поиска в конечном итоге позволяет достичь точного позиционирования, этот процесс занимает много времени: для полного опыления одного цветка требуется почти 19 секунд. Если точность конечной эффектора может быть повышена, эффективность точного позиционирования по круговой траектории поиска значительно выиграет.

Как традиционные методы N DUC Tai, так и роботы-опылители, основанные на глубоком обучении STRADER J, Хубайба Ахмада и YANG, существенно влияют на успешность и эффективность операций опыления из-за ошибок в оценке положения целей опыления. Например, роботы-опылители N DUC Tai и YANG могут обеспечить успешное опыление только за счет поддержания большой зоны поиска сервоприводов, что приводит к снижению эффективности опыления. Следовательно, наша работа предлагает метод глубокого обучения для изучения ошибок поступательного и вращательного движения между цветком и конечным эффектором опыления.

За счет компенсации этих ошибок повышается точность позиционирования рабочего органа робота. Такое сокращение диапазона и пути поиска сервомеханизма в конечном итоге повышает эффективность процесса опыления.

2.3. Архитектура трансформатора и кодирование положения

Архитектура трансформатора, представленная Васвани и др. [21] существенно повлияла на обработку естественного языка (НЛП) и компьютерное зрение. Трансформаторы используют механизм самообслуживания для захвата сложных зависимостей во входных данных, что делает их эффективными для понимания визуальной информации. В компьютерном зрении преобразователи обрабатывают изображения, сегментируя их на фрагменты линейно встраивая эти сегменты, обеспечивая мощные механизмы внимания для таких задач, как классификация изображений, обнаружение объектов и создание описаний изображений. В робототехнике трансформаторы могут прогнозировать смещение ошибок кончика роботизированной руки, анализируя последовательности изображений или данные датчиков, повышая точность и достоверность.

Введение кодирования положения [22] для прогнозирования ошибки поступательного смещения и ошибки смещения вращательной позы на конце роботизированной руки еще больше улучшает пространственную осведомленность и точность. Встраивая информацию о пространственном положении непосредственно в модель преобразователя, она повышает способность модели различать относительные и абсолютные положения объектов на сцене, что имеет решающее значение для точной оценки ошибок.

Механизм самообслуживания преобразователей может фиксировать долгосрочные зависимости, позволяя модели напрямую рассчитывать отношения между любыми двумя элементами в последовательности входных признаков изображения, учитывая все входные данные, а не только локальную информацию. Эта характеристика помогает уменьшить проблему локального оптимума. Кроме того, благодаря детальному распределению внимания модели на основе преобразователей могут выявлять и подчеркнуть особенности и взаимосвязи, наиболее важные для текущей задачи. Поэтому использование модели трансформатора, оснащенной позиционным кодированием для прогнозирования ошибок поступательного и вращательного движения между конечным эффектором робота-опылителя и целевым объектом, является жизнеспособным подходом.

3. Метод

3.1. Ошибка

Смещение Чтобы описать ошибку поступательного смещения и ошибку смещения вращательной позы, необходимо построить две декартовы системы координат, SA и SB, на целевом цветке

концевой э ф фектор робота-опылителя соответственно. Декартова система координат CA, построенная на цветке, имеет начало O на конце пестика. Плоскость, образованная осями x и y, параллельна плоскости лепестков цветка, а ось z параллельна пестику и направлена вглубь, как показано на рис. 2б,в. Декартова система координат CB, построенная на конце робота-опылителя, имеет начало O на конце кисти, полученное путем перевода системы координат ТСП роботизированной руки UR5, как показано на рисунке 2д. CA можно получить из CB через матрицу перемещения - вращения $TR_{4 \times 4}$:

$$TR = \begin{pmatrix} P_{11} & P_{12} & P_{13} & t_1 \\ R_{21} & R_{22} & R_{23} & t_2 \\ P_{31} & P_{32} & P_{33} & t_3 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (1)$$

$$CA = TR \cdot CB \quad (2)$$




Рисунок 2. (а) Идеальное положение опыления с нулевой ошибкой. (б– г) Положения декартовых систем координат на цветке и на конце роботизированной руки соответственно.

Ошибка поступательного смещения и ошибка смещения вращательной позы представляют собой вектор перемещения t и вектор вращения, полученные из матрицы вращения R матрицы перемещения - вращения TR соответственно:

$$t = \begin{pmatrix} t_1 \\ t_2 \\ t_3 \end{pmatrix} \quad T \quad (3)$$

$$P = \begin{pmatrix} P_{11} & P_{12} & P_{13} \\ P_{21} & P_{22} & P_{23} \\ P_{31} & P_{32} & P_{33} \end{pmatrix} \quad (4)$$

Когда концевой э ф фектор робота-опылителя находится в идеальной позе опыления, значения ошибки поступательного смещения и ошибки смещения вращательной позы приближаются к нулю. В этот момент кисть на конце робота-опылителя перпендикулярна плоскости лепестков целевого цветка и точно соприкасается с пестиком, т. е. системы координат CA и CB совпадают, как показано на рисунке 2а.

$$\theta = \cos^{-1} \left(\frac{\text{трассировка}(R)}{\sqrt{2}} \right) \quad (5)$$

$$V = \frac{1}{2 \sin(\theta)} \begin{pmatrix} P_{32} & P_{23} \\ P_{13} & P_{13} \\ P_{21} & P_{12} \end{pmatrix}$$

$$W = \theta \quad V$$

Ошибка поступательного смещения и ошибка смещения вращательной позы предсказанные моделью, обозначаются как $\hat{t}$ и $\hat{R}$ соответственно. Разница между фактической и прогнозируемой ошибкой поступательного смещения и ошибкой смещения вращательной позы от конца роботизированной руки до пестика целевого цветка рассчитывается как поступательная ошибка (TE) и вращательная ошибка (RE) соответственно. Согласно уравнению (5), матрицы вращения R и $\hat{R}$ могут быть преобразованы в векторы вращения W и $\hat{W}$:

$$TE = \hat{t} - t \quad (6)$$

$$PE = 1 - \frac{w}{w + w} \quad (7)$$

Единицей TE являются сантиметры(см), представляющие пространственное расстояние между прогнозируемой ошибкой перевода и фактической ошибкой перевода. RE является безразмерным и представляет собой косинусное расстояние между прогнозируемой ошибкой вектора вращения и фактической ошибкой вектора вращения.

3.2. Модуль Внимания

Модуль внимания реализован на основе механизма самоконтроля, который позволяет модели взвешивать важность различных функций в различных данных. Применяя этот механизм, модель может адаптивно концентрировать вычислительные ресурсы на областях изображения, которые содержат ключевую информацию для прогнозирования смещения позы (Tx, Ty, Tz, Wx, Wy, Wz). Более того, благодаря внедрению кодирования положения в механизм самообслуживания модель достигает полного понимания изображения. Это дает дополнительную информацию для решения проблем симметрии при прогнозировании позы объекта, повышает точность модели и расширяет ее общие возможности в различных сценариях, с которыми сталкиваются роботы-опылители. Этот метод не только повышает точность модели, но и усиливает ее универсальность в разнообразных условиях, с которыми сталкиваются роботы-опылители.

3.3. Извлечение функций

Учитывая уникальную способность моделей-трансформеров обрабатывать данные изображений, мы используем предварительно обученную сверточную нейронную сеть ResNet-50 [23] в качестве сети выделения признаков для преобразования исходных изображений в многомерные векторы признаков. Эти характеристики затем передаются в модель трансформатора для дальнейшей обработки. Мы сравниваем сети извлечения признаков разной глубины, чтобы определить оптимальное представление признаков. Этот подход использует сильную способность ResNet-50 фиксировать подробные пространственные иерархии в изображениях, предоставляя богатый набор функций для анализа модели преобразователя. Включив эту гибридную архитектуру, сочетающую сильные стороны CNN в извлечении признаков с усовершенствованным механизмом внимания преобразователей, модель достигает детального понимания содержания изображения, необходимого для прогнозирования ошибки смещения позы. Этот метод облегчает идентификацию и сосредоточение внимания на важнейших аспектах различных данных, тем самым повышая точность и эффективность процесса оценки позы.

3.4. Предлагаемый подход

В этой работе представлена новая сетевая модель, включающая модуль внимания, предназначенный для повышения точности прогнозирования за счет сосредоточения внимания на наиболее важных частях различных данных. Эта модель особенно подходит для анализа данных изображения, полученных конечным фактором робота-опылителя, с целью точно предсказать смещение положения конечного фактора относительно целевого объекта в декартовой системе координат. В время обучения модель принимает данные изображения с конца роботизированной руки в качестве входных данных и выводит шестимерный вектор (Tx, Ty, Tz, Wx, Wy, Wz), представляющий поступательное смещение $W = (Wx, Wy, Wz)$ в ошибках $T = (Tx, Ty, Tz)$ и трех направлений в декартовой системе координат. ошибках вращательного смещения по

3.5. Прогнозирование ошибки

Смещения Вх одними данными для модели являются RGB-изображение, снятое RGB-камерой «глаз в руке» на роботизированной руке, отображающее позиционное состояние конечного фактора роботизированной руки во время опыления и цветка опыления. Вх одними данными являются вектор, представляющий вектор смещения позы (Tx, Ty, Tz, Wx, Wy, Wz), который включает в себя поступательные и вращательные ошибки конечного фактора робота относительно целевого объекта. Для достижения этой цели в модели используются две нейронные сети прямого распространения, которые напрямую отображают функции, ориентированные на внимание.

в трех мерное пространствосмещения и трех мерное пространствовращения . Рисунок 3 иллюстрирует весь алгоритмический процесс.




Рисунок 3. Схема иллюстрирует работу предлагаемого алгоритма. Процесс начинается с вх одно изображения , которое подвергается извлечению признаков с помощью сверточной нейронной сети (CNN) для получения многомерных признаков изображения . Эти функции затем дополняются позиционным кодированием перед вводом в модуль преобразователя . Выходной сигнал трансформатора далее обрабатывается двумя отдельными нейронными сетями прямой распространения , которым поручено прогнозировать поступательные и вращательные ошибки соответственно.

3.6. Сетевая архитектура

В этой работе мы приняли специальную модель трансформатора, предназначенную для обработки функций сериализованного изображения и прогнозирования ошибки поступательного смещения и ошибки смещения вращательной позы конце роботизированной руки. Мы модифицировали исходную модель преобразователя , введя двумерное позиционное кодирование , чтобы сохранить пространственную информацию входов изображений . Выходной слой настроен для генерации трех мерного поступательного смещения и вектора ошибки смещения вращательной позы . Как показано на рисунке 4, ResNet50 служит основой для извлечения богатого набора функций из входов данных изображений . Чтобы сохранить пространственную информацию среди элементов изображений , мы применяем синусоидальное кодирование положения к извлеченным объектам , которые затем суммируются с объектами перед подачей в кодировщик . Для захвата информации из разных подпространств в кодере используется многоголовочный механизм внимания с пятью головками . Выходной сигнал кодера впоследствии подается в декодер . Следуя стандартной архитектуре преобразователя , декодер использует механизм внимания с несколькими головками для преобразования двух вложенных размеров d . Эти объекты запроса преобразуются декодером в выходные вложения , которые затем декодируются двумя отдельными сетями прямой связи в ошибку поступательного смещения и ошибку смещения вращательной позы соответственно.




Рисунок 4. Основная модель использует ResNet50 в качестве магистральной сети для изучения высокоуровневых функций из входов одно изображения . Эти функции затем дополняются позиционным кодированием перед передачей в кодер . Впоследствии декодер сначала вводит вектор признаков для ошибки поступательного смещения , который используется в качестве входных данных для нейронной сети прямой распространения , предназначенной для прогнозирования . Этот вектор признаков затем используется в качестве входных данных запроса для декодера , в результате чего получается другой вектор признаков , который передается в отдельную нейронную сеть прямой распространения для прогнозирования ошибки смещения вращательной позы .

4. Эксперименты

4.1. Предварительная обработка данных

Все данные изображения, использованные в этом эксперименте, взяты из собственного набора данных, который состоит из изображений, снятых камерой, установленной на роботизированной руке, во время опыления процесс, в котором каждое изображение уникальным образом представляет позу цветка, подлежащего опылению. Как показано на рисунке 5, ориентация цветов относительно конца роботизированной руки была разделена на пять направлений: влево, вправо, вверх, вниз и вперед. Подробная статистическая информация представлена в Таблице 1.




Рисунок 5. Цветки с разной ориентацией относительно концевой эффектора роботизированной руки.

Таблица 1. Набор данных включает количество изображений цветов, ориентированных в разные стороны относительно к конечному эффектору роботизированной руки.

Ориентации	Количествоцветов	Доля (%)
л	261	20,6
р	274	21,7
ф	230	18,2
ты	256	20.3
Д	243	19.2

«F», «L», «R», «U» и «D» обозначают ориентацию вперед, влево, вправо, вверх и вниз.

Чтобы обеспечить согласованность входных данных, все изображения, снятые роботизированной рукой, конечная камера сначала была изменена до единого разрешения (224 × 224). Впоследствии изображения были нормализованы, масштабируя значения пикселей до диапазона [0, 1], чтобы повысить стабильность обучения модели. Кроме того, был применен ряд методов увеличения данных, включая масштабирование, обрезку и преобразование цвета, чтобы увеличить разнообразие данных и предотвратить переобучение. Что касается данных этикетки, мы предположили, что

установить ошибку $T = (T_x, T_y, T_z)$ и ошибку смещения вращения $W = (W_x, W_y, W_z)$, $\|T\| < D$, где D — константа. Ошибка смещения позиции Уравнение (8) и

ошибка смещения вращения. Уравнение (9) было нормализовано и масштабировано до [−1, 1] следующим образом

$$T_n = \frac{T}{D} \tag{8}$$

$$W = \theta \cdot V \tag{9}$$

$$\theta = \sqrt{W_x^2 + W_y^2 + W_z^2} \tag{10}$$

$$V = \left(\frac{W_x}{\theta}, \frac{W_y}{\theta}, \frac{W_z}{\theta} \right) \tag{11}$$

Символ θ в уравнении (10) представляет угол поворота, а V обозначает угол поворота. единичный вектор вдоль оси вращения. Нормализованные данные метки были $(T_n, V, \frac{\theta}{2\pi})$.

4.2. Метрики оценки

В модели, представленной в этой статье, мы отдельно прогнозируем поступательное смещение ошибка и ошибка смещения вращательной позы таким образом разрабатывая две функции потерь. Первая потеря

Функция под названием LossT измеряет среднеквадратичное расстояние между ошибкой смещения пространственного положения, предсказанной моделью для конечного фактора роботизированной руки опыления, допестика целевого цветка, и фактической ошибкой пространственного смещения. LossT определяется следующим образом:

$$\text{Потеря } T = \frac{1}{2m} \sum_{x \in M} (\hat{T}_n - T_n)^2 \quad (12)$$

где M — набор тестовых данных, m — количество элементов в наборе, а $\hat{T}_n$ — ошибка поступательного смещения, предсказанная моделью, и истинная ошибка поступательного смещения, полученная с помощью уравнения (8) соответственно.

Вторая функция потерь, названная LossR , измеряет несоответствие между ошибкой пространственного вращения, предсказанной моделью для конечного фактора роботизированной руки опыления и пестика целевого цветка, и фактической ошибкой пространственного вращения. LossR определяется следующим образом:

$$\text{Потери } R = \frac{1}{2m} \sum_{x \in M} \left(\frac{1}{2\sigma_1} (\hat{\theta} - \theta)^2 \right) + \frac{1}{2\sigma_2} \left(1 - \frac{\hat{V} \cdot V}{|V|^2} \right) + \log(\sigma_1 \sigma_2) \quad (13)$$

где M — набор тестовых данных, а m — количество элементов в наборе. Переменные $\hat{\theta}$, θ , $\hat{V}$, и V представляют прогнозируемые и фактические углы оси вращения, полученные с помощью уравнения (9)–(11), где σ_1 и σ_2 являются параметрами, которые необходимо изучить.

Комбинированная функция потерь, используемая для обучения модели, определяется как

$$\text{Потеря} = \alpha \text{LossT} + \beta \text{LossR} \quad (14)$$

Эта функция потерь в уравнении (14) весторонне измеряет потери на ошибку поступательного смещения и потери на ошибку вращательного смещения во время обучения модели. Параметры α и β — это гиперпараметры, представляющие веса, которые необходимо систематически корректировать во время обучения модели.

4.3. Детали обучения

Обучение модели проводилось в вычислительной среде, оснащенной графическими процессорами NVIDIA V100. Мы использовали оптимизатор Адама [24] с начальной скоростью обучения, установленной на 0,01, и применили стратегию снижения скорости обучения, которая постепенно снижала скорость обучения до 0,00001 по мере прохождения обучения. В процессе обучения использовалась пользовательская функция потерь, уравнение (14). При обучении модели настройка гиперпараметров в уравнении (14) повлияла на способность модели сходиться. После обширных экспериментов мы наконец установили $\alpha = 0,0025$ и $\beta = 1$, что позволило модели легче сходиться во время обучения.

В наборе данных цветы с разной ориентацией были случайным образом перетасованы, а затем данные были разделены на 10 подмножеств с использованием метода К-кратной перекрестной проверки. Каждый раз одно подмножество использовалось в качестве тестового набора, а остальные девять подмножеств — в качестве обучающего набора. Этот процесс повторялся 10 раз. Во время обучения модели мы заметили, что модель сначала быстро сходилась, а затем постепенно стабилизировалась. На рисунке 6 показаны изменения значений потерь, поступательной ошибки и ошибки вращения в процессе обучения модели:




Рисунок 6. Изменения потерь, TE и RE в процессе обучения модели.

4.4. Полученные результаты

Насколько нам известно, мы первыми предсказали ошибку поступательного смещения и ошибку смещения вращательной позы концевой ф фектора роботизированной руки относительно целевого объекта с использованием только информации об изображении RGB. Поэ тому в данной статье основное внимание уделя ется повышению точности. ошибки поступательного смещения и ошибки смещения вращательного положения концевой ф фектора робота при использовании предложенного нами метода по сравнению с современным методом YANG [18] как базов ый уровень. Кроме того, мы подчеркиваем повышение э ф фективности опыления одиноч ный цветок.

Мы провели э ксперименты с цветками разной ориентации в группах , чтобы проанализировать ошибки поступательного и вращательного смещения , а также скорость обнаружения . Результаты э ксперимента показали небольшие различия для цветов с разной ориентацией. Как показано в Таблице 2 и Рисунок 7: цветы обраще ные вперед, достигли наилучших результатов с точки зрения точности э ксперимента. с наименьшей ошибкой поступательного смещения и ошибкой смещения вращательной позы по сравнению с цветами других ориентация х . Следующими были цветы обраще нные вверх . Из-за э кологических симметрии, не было почти никакой разницы в результатах для цветов, обраще нных влево и вправо. Цветы лицом вниз имели худшие результаты как с точки зрения поступательной ошибки смещения , так и с точки зрения ошибки смещения вращательной позы. Однако скорость обнаружения модели для цветов с различие ориентации оставались почти постоя нными.

Таблица 2. Результаты э кспериментов модели на цветках различной ориентации.

Ориентации	ТЭ	РЭ	Ф ПС
л	0,82	0,0049	41
р	0,82	0,0049	42
Ф	0,78	0,0047	43
ты	0,80	0,0048	42
Д	0,87	0,0051	41

«F», «L», «R», «U» и «D» обозначают ориентацию вперед, влево, вправо, вверх и вниз.




Рисунок 7. Распределение ошибок обнаружения вращения и поступательного движения модели для цветов с различие ориентации, а также скорость обнаружения .

Мы провели э ксперименты с использованием робота-опылителя YANG. Процесс опыления одного цветка роботом-опылителем YANG можно разделить на пять э тапов.

х ронологический порядк. После четвертого шага точность позиционирования концевой э ф фектора робота-опыления YANG относительно целевого пестика составила 1,5 см. На э том э тапе мы представили нов ый шаг под названием «Точная регулировка положения ». В в о дим изображение позыветка относительно конечного э ф фектора робота в нашу обученную модель, чтобы предсказать поступательное и ошибки смещения вращения . На основе прогнозируемых значений поза робота-опылителя концевой э ф фектор был отрегулирован

Как показано в Таблице 3, благодаря новому шагу «Точная регулировка положения » расстояние поступательного движения и несоответствие вращения между концевым э ф фектором робота-опылителя и целью опыления была еще больше уменьшена, что сузило диапазон для следующего поиска сервомотора. э та опыления . Наши э ксперименты показали, что среднее время опыления с помощью сервопоиска составило всего 3,1 с, при э том уровень успешности опыления был сопоставим с опылением YANG. робот на 86,19%. Как показано в Таблице 4, после применения нашего метода к роботу-опылению, достигнута средняя точность расстояния между концевым э ф фектором робота и целевым пестиком 0,81 см, улучшение на 46,67%. Ошибка смещения вращательной позиции, рассчитанная в соответствии с к уравнению (14) также достигло 0,0049. Общее время завершения опыления одного ц веток сократился почти вдвое, при э том среднее повышение э ф фективности составило 50,9%.

Таблица 3. Сравнение средних временных затрат на каждом э тапе системы опыления после внедрения нашего метода.

Шаг	ЯН (базов ый уровень)	Наши затраты времени (S)
	Стоимость времени (S)	
Обнаружение цветов	0,0928	0,0927
Идентификация пестика	0,025	0,024
Расчет положения (включая движение робота)	1,8	1,8
Дотя гивание цветов (включая движение робота)	4.2	4.2
Положение точной регулировки	/	0,024
Сервопривод (включая движение робота)	12,7	3.1

Шаг «Точная регулировка положения » я вля ется дополнительным шагом. С учетом э того шага время , проведенное в режиме «Обслуживание», шаг значительно сокращается , и тот же уровень успешного опыления достигается всего за 3,1 с. Все номера записаны в секундах .

Таблица 4. Сравнение ошибки поступательного смещения и ошибки смещения вращательной позы при применении нашей алгоритм для цветов, ориентированных в разных направлениях по сравнению с базовой линией.

Ориентации	Метод	Т Э	Р Э	Стоимость времени (с)
л	ЯН	1,53	/	18,78
	Наш	0,82	0,0050	9.22
р	ЯН	1,52	/	18.80
	Наш	0,82	0,0050	9.23
ф	ЯН	1,48	/	18.85
	Наш	0,80	0,0048	9.22
ты	ЯН	1,53	/	18.79
	Наш	0,81	0,0049	9.24
Д	ЯН	1,55	/	18.83
	Наш	0,83	0,0052	9.26

«F», «L», «R», «U» и «D» обозначают ориентацию вперед, влево, вправо, вверх и вниз. метод ЯН служил базовой линией.

В э той статье было проведено несколько э кспериментов по абля ции, чтобы проверить влияние различных магистральные сети и добавление позиционного кодирования для прогнозирования модели ошибки поступательного смещения и ошибки смещения вращательной позы ResNet50, Resnet18, Resnet101, В качестве магистральной функции были выбраны VGG16, VGG19, DenseNet-121 и DenseNet-201. добывающие сети. Для каждой магистрали э ксперименты проводились с и без позиционное кодирование. Результаты э ксперимента, показанные в Таблице 5 и Рисунке 8, указывают на что различные магистрали и добавление позиционного кодирования существенно влияют на

окончательная точность прогноза модели. Версия модели с ResNet50 в качестве основы. Добавлена сеть извлечения признаков и позиционное кодирование, что позволило достичь наилучшей производительности. при прогнозировании ошибки поступательного смещения и ошибки смещения вращательной позы, достигая 8,1 мм и 0,0049 соответственно.

Таблица 5. Влияние различных магистралей в модели на точность прогнозирования ошибки поступательного смещения и ошибки смещения вращательной позы

Магистральные сети	Позиционное кодирование	ТЭ	РЭ
РесНет50	Галочка	0,81	0,0049
	Крестик	1.19	0,0051
Реснет18	Галочка	0,92	0,0053
	Крестик	1.33	0,0054
Реснет101	Галочка	0,86	0,0050
	Крестик	1.21	0,0050
ВГГ16	Галочка	0,96	0,0053
	Крестик	1.32	0,0055
ВГГ19	Галочка	0,99	0,0054
	Крестик	1.33	0,0055
Плотная сеть-121	Галочка	0,92	0,0054
	Крестик	1.23	0,0055
Плотная сеть-201	Галочка	1.10	0,0055
	Крестик	1,38	0,0057

Галочка (✓) указывает на то, что в модель включено позиционное кодирование, а крестик (✗) указывает на то, что модель не включала позиционное кодирование.




Рисунок 8. Распределение поступательной и вращательной ошибки для различных магистральных моделей с и без добавления позиционного кодирования.

5. Обсуждение

В этой работе предлагается подход на основе трансформатора, который обеспечивает сквозное прогнозирование. поступательных и вращательных ошибок между концевым звеном фактором роботизированной руки-оператора

и целевое положение опыления, исключительно с использованием информации изображения RGB. Наши экспериментальные результаты показывают, что этот метод эффективно сужает диапазон ошибок роботизированного концевого эффектора в пределах известного предела погрешности, тем самым повышая общую эффективность роботизированного опыления.

В этой работе наш метод продемонстрировал небольшие различия в результатах при работе с цветами разной ориентации, особенно большие ошибки поступательного и вращательного движения с цветами, обращенными вниз. Это может быть связано с позиционированием угла камеры работы относительно ориентации цветов, что усложняет точное распознавание и локализацию цветов в определенной ориентации. Путем экспериментов мы также заметили, что версии модели, в которых использовалось позиционное кодирование, лучше справлялись с точным прогнозированием поступательных и вращательных ошибок. Кроме того, различные магистральные сети, используемые для извлечения признаков из их одних изображений, оказали значительное влияние на производительность модели.

Эта работа имеет потенциальные ограничения, несмотря на продемонстрированную эффективность предлагаемого метода в уменьшении поступательных и вращательных ошибок между конечным эффектором робота-опылителя и мишенью: (1) Набор данных, используемый в этом исследовании, был специально собран для экспериментальных целей, что может ограничить возможности обобщения модели в различных средах и типах цветов; (2) Производительность модели может ухудшиться при различных условиях освещения и в условиях препятствий, что влияет на ее общую эффективность. Эти проблемы подчеркивают необходимость дальнейших усовершенствований перед практическим внедрением, что требует будущих исследований для изучения дополнительных методов, которые улучшат адаптируемость и надежность модели в различных сельскохозяйственных условиях.

6. Выводы

В этой работе представлен инновационный метод, который использует мощные возможности пространственного обучения и понимания модели глубокого обучения на основе трансформатора для достижения сквозного прогнозирования поступательных и вращательных ошибок между конечным эффектором робота-опылителя и целевой позицией опыления, используя только RGB-изображений. Наши экспериментальные результаты показывают, что этот метод эффективно для дальнейшего уменьшения диапазона ошибок конечного эффектора робота-опылителя в пределах известного диапазона ошибок, тем самым улучшая общую эффективность робота-опылителя. Будущая работа может быть сосредоточена на исследовании прогнозирования поступательных и вращательных ошибок между роботизированным конечным эффектором и целевыми позициями в наборах данных, содержащих более разнообразный диапазон типов цветов, при различных условиях освещения и окклюзии. Такая работа будет направлена на повышение надежности и возможностей обобщения модели, обеспечивая реальный подход к повышению точности обычных роботизированных конечных эффекторов.

Вклад авторов: Концептуализация, JX; методология, JX; проверка, JX; формальный анализ, JX, JC, HP и MY; исследование, JX; ресурсы, JX; курирование данных, JX; письмо — подготовка первоначального черновика, JX, HP и MY; написание — обзор и редактирование, JX, HP и MY; визуализация, JX; супервизия, HP, MY и JC; администрация проекта, JC. Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: Данная работа финансировалась в рамках проекта «Ключевой план исследований и разработок Гуанси» (AB24010164; AB21220038).

Заявление одобрения: Данные, подтверждающие выводы этой работы, можно получить у соответствующего автора по обоснованному запросу.

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Сокращения

В данной рукописи использованы следующие сокращения:

ошибка перевода TE

Ошибка вращения RE

Рекомендации

1. Бингс, К. Роботизированные насекомые могут опылять цветы и находить жертв стихийных бедствий. Популярная наука, 17 декабря 2009 г.

2. Уильямс, Х.; Неджати, М.; Хусейн, С.; Пенк-олл, Н.; Лим, Ю.; Джонс, Миннесота; Белл, Дж.; Ан-ХС; Брэдли, С.; Шаре, П.; и другие. Автономное опыление отдельных цветков киви: на пути к роботу-опылителю киви. Дж. Полевой робот. 2020, 37, 246–262. [\[Перекрестная ссылка\]](#)

3. Гао, К.; Он-Л.; Фанг, В.; Ву, З.; Цзянь-Х.; Ли, Р.; Фу, Л. Новый робот для опыления цветка киви, основанный на предпочтительном методе опыления. Выбор цветов и точная цель. Выпустить. Электрон. Сельское хозяйство. 2023, 207, 107762. [\[CrossRef\]](#)

4. Стрейдер, Дж.; Нгуен, Дж.; Тач, К.; Ду, Ю; Лассак, К.; Баззо, Б.; Уотсон, Р.; Цербоне, Х.; Оки, Н.; Ян, К.; и другие. Подсистема взаимодействия цветов для робота точного опыления. В материалах Международной конференции IEEE/RSJ по интеллектуальным роботам и системам (IROS) 2019 г., Макао, Китай, 3–8 ноября 2019 г.; стр. 5534–5541.

5. Цзиньфелт, Т.; Джамшиди, ММ; Агаянс. Роботизированная система стыковочного крана с обратной связью по зрению, применимая для опыления ванили. Между. Дж. Автомат. Контроль 2013, 7, 62–82. [\[Перекрестная ссылка\]](#)

6. Юань, Т.; Чжао, С.; Шэн, Х.; Ван, Д.; Гонг, Ю; Ли, В. Автономный робот-опылитель для гормональной обработки цветков томатов в теплице. В материалах 3-й Международной конференции по системам информатики (ICSAI) 2016 г., Шанхай, Китай, 19–21 ноября 2016 г.; стр. 108–113.

7. Аброт, Д.П. Биология опыления: сохранение биоразнообразия и сельскохозяйственное производство. Том 792; Спрингер: Нью-Йорк, штат Нью-Йорк, США, 2012 г.

8. Ян, Х.; Мияко, Э. Опыление мыльными пузырями. Iscience 2020, 23, 101188. [\[CrossRef\]](#) [\[PubMed\]](#)

Хингершойссер, С.; Каньяр, К.; Илич, С.; Шурм, П.; Наваб, Н.; Фуа, П.; Лепетит, В. Карты градиентного отклика для обнаружения бестекстурных объектов в реальном времени. IEEE Транс. Паттерн Анал. Мах. Интел. 2011, 34, 876–888. [\[Перекрестная ссылка\]](#) [\[PubMed\]](#)

10. Цао, З.; Шейх, Ю; Банерджи, Северная Каролина Масштабируемая оценка вызовов в реальном времени для бестекстурных объектов. В материалах Международной конференции IEEE по робототехнике и автоматизации (ICRA) 2016 г., Стокгольм, Швеция, 16–21 мая 2016 г.; стр. 2441–2448.

11. Брахманн, Э.; Крулл, А.; Мишель, Ф.; Гумхольд, С.; Штотт, Дж.; Ротер, К. Обучение оценке познания трехмерного объекта с использованием координат трехмерного объекта. В материалах, часть II 13, Труды компьютерного зрения – ECCV 2014: 13-я Европейская конференция, Цюрих, Швейцария, 6–12 сентября 2014 г.; Springer: Берлин/Гейдельберг, Германия, 2014 г.; стр. 536–551.

12. Крулла, А.; Брахманн, Э.; Мишель, Ф.; Ян, МД; Гумхольд, С.; Ротер, К. Обучение анализу путем синтеза для оценки бд-позы изображения x RGB-D. В материалах Международной конференции IEEE по компьютерному зрению, Сантьяго, Чили, 7–13 декабря 2015 г.; стр. 954–962.

13. Сян, Ю; Шидт, Т.; Нарайанан, В.; Фокс, Д. Посекн. Сверточная нейронная сеть для оценки познания объектов в загроможденных сценах. arXiv 2017, arXiv:1711.00199.

14. Ли, К.; Хо, Ю; Лю, Ю; Ши, Ю; Цзянь, К.; Кюи, Ю. Разработка легкого роботизированного манипулятора для опыления киви. Выпустить. Электрон. Сельское хозяйство. 2022, 198, 107114. [\[CrossRef\]](#)

15. Ма, В.П.; Ли, WX; Цао, PX. Метод позиционирования объектов с помощью бинокулярного зрения для роботов, основанный на грубом точном стереопоставлении. Между. Дж. Автомат. Выпустить. 2020, 17, 562–571. [\[Перекрестная ссылка\]](#)

16. Тай, Северная Дакота; Трие, Нью-Мексико; Тиц, Н.Т. Моделирование положения и ориентации цветков дыни для автоматического опыления. сельское хозяйство. 2024, 14, 746. [\[CrossRef\]](#)

17. Ахмад, К.; Парк, Ж-Э; Ильяс, С.Т.; Ли, Дж-Х.; Ким, С.; Ким, Х. Точное и надежное опыление арбузов с помощью интеллекта управляемое визуальное обслуживание. Выпустить. Электрон. Сельское хозяйство. 2024, 219, 108753. [\[CrossRef\]](#)

18. Ян, М.; Лю, Х.; Чжао, Ю; Саң, Ю; Паң, Х.; Саң, К.; Чең, Дж.; Цянь, Б.; Ян, Х. Доставка пыльцы на пестики цветка фрезии. автономно и точно с помощью роботизированной руки. Выпустить. Электрон. Сельское хозяйство. 2023, 214, 108274. [\[CrossRef\]](#)

19. Чжоу, К. Yolast++ Улучшенная сегментация экземпляров в реальном времени; Калифорнийский университет Дэвис, Калифорния, США, 2020.

20. Карион, Н.; Месса, Ф.; Синев, Г.; Усунье, Н.; Кириллов, А.; Загройко, С. Сквозное обнаружение объектов с помощью преобразователей. В Европейской конференции по компьютерному зрению; Спрингер: Чам, Швейцария, 2020 г.; стр. 213–229.

21. Вассани, А.; Шазир, Н.; Пармар, Н.; Ушкорейт, Дж.; Джонс, Л.; Гомес, АН; Кайзер, Л.; Полосухин, И. Внимание – это все, что вам нужно. arXiv 2017, arXiv:1706.03762v7.

22. Цзянь, К.; Пэн, П.; Лиан, Ю; Сюй, В. Метод кодирования вложенных позиций в преобразователе изображения. Дж. Вис. Комп. Изображение представляет. 2022, 89, 103664. [\[CrossRef\]](#)

23. Он, К.; Чжао, Х.; Рен, С.; Саң, Дж. Глубокое остаточное обучение для распознавания изображений. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Лас-Вегас, Невада, США, 27–30 июня 2016 г.; стр. 770–778.

24. Кингма, ДП; Ба, Дж. Адам: Метод стохастической оптимизации. arXiv 2014, arXiv:1412.6980.

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участнику(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.



Статья

Адаптивные корреляционные фильтры с подавлением аберрантности Совместная оптимизация в многомерных беспилотных системах Распределение задач летательного аппарата и планирование траектории

Цзыцзе Чжэн ^{1,*}, Чжицзюнь Чжан ¹, Чжэньчжан Ли ², Киуда Ю ¹ и Я Цзян ¹¹ Школа автоматизации и инженерии, Южно-Китайский технологический университет, Гуанчжоу 510006, Китайская² школа математики и системных наук, Гуандунский политехнический педагогический университет, Гуанчжоу 510665, Китай; zhenzhangli@gpnu.edu.cn

* Переписка: 201910102802@mail.scut.edu.cn.

Аннотация: В быстро развивающейся области применения беспилотных летательных аппаратов (БПЛА) сложность планирования задач и оптимизации траектории, особенно в многомерных операционных средах, становится все более сложной. В настоящем исследовании эти проблемы решаются путем разработки алгоритма совместной оптимизации адаптивного корреляционного фильтра подавления искажений (ARCF-ICO), предназначенного для многомерного распределения задач БПЛА и планирования траектории. Алгоритм ARCF-ICO сочетает в себе передовые технологии корреляционного фильтра с методами многокритериальной оптимизации, повышая точность планирования траектории и эффективность распределения задач. Учитывая погодные условия и другие факторы окружающей среды, алгоритм обеспечивает надежную работу на малых высотах. Алгоритм ARCF-ICO повышает стабильность и точность отслеживания БПЛА за счет подавления искажений, способствуя выбору оптимального пути и выполнению задач. Экспериментальная проверка с использованием наборов данных UAV123@10fps и OTB-100 показывает, что алгоритм ARCF-ICO превосходит существующие методы по метрикам «Площадь под кривой» (AUC) и «Точность». Кроме того, учет энергопотребления и срока службы батареи в алгоритме еще раз подтверждает его применимость к современным технологиям БПЛА. Это исследование продвигает планирование миссий БПЛА и устанавливает новые стандарты для использования БПЛА как в гражданских, так и в военных целях, где адаптивность и точность имеют решающее значение.

Ключевые слова: многокритериальная оптимизация; планирование траектории БПЛА; корреляционные фильтры; адаптивные алгоритмы; распределение задач



Цитирование: Чжэн З.; Чжан, З.; Ли, З.; Ю, К.; Цзян, Ю. Адаптивные корреляционные фильтры с подавлением аберрантности и совместной оптимизацией в распределении задач и планировании траектории многомерных беспилотных летательных аппаратов. Электроника 2024, 13, 3071. <https://doi.org/10.3390/electronics13153071>

Научный редактор: Чжицзоань Лю

Поступила: 29 мая 2024 г.

Пересмотрено: 20 июля 2024 г.

Принято: 30 июля 2024 г.

Опубликовано: 2 августа 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

В эпоху Интернета вещей беспилотные летательные аппараты (БПЛА) стали важными инструментами в различных областях благодаря своей гибкости и эффективности. По мере увеличения сложности и разнообразия миссий БПЛА потребность в расширенном многоцелевом распределении задач и планировании траекторий становится критической. Недавние исследования Chen et al. [1–3] представили инновационные алгоритмы, которые улучшают планирование пути и совместное управление поведением гетерогенных БПЛА. Эти методы повышают эксплуатационную эффективность и адаптируемость БПЛА в динамичных и сложных средах, решая современные проблемы развертывания БПЛА.

Быстрое развитие технологии БПЛА привело к растущему спросу на приложения БПЛА в многозадачных средах. Однако в сложных многоцелевых средах один БПЛА часто с трудом справляется с несколькими задачами одновременно, что требует совместной работы нескольких БПЛА. Исследования по многомерному распределению задач многоцелевого БПЛА и планированию траектории на основе глубокого обучения направлены на решение проблем оптимизации при совместном распределении задач нескольких БПЛА, достижении интеллектуального управления и планирования БПЛА для повышения эффективности и точности выполне

В сфере национального стратегического развития развитие и использование технологий беспилотных летательных аппаратов (БПЛА) становятся ключевыми технологическими средствами реализации стратегических инициатив. Благодаря совершенствованию планирования задач БПЛА ключевые отрасли внутри страны смогут стать свидетелями повышения уровня производительности и эффективности, тем самым способствуя развитию новой, высококачественной производительности - концепции, которую отстаивают Яо и Лю [5]. Их работа подчеркивает важность определения теоретических основ и практических путей достижения прогресса. Более того, эволюция технологии БПЛА не только увеличивает технологические возможности страны, но и укрепляет ее глобальную конкурентоспособность, как показали Ма и Чен [6]. Их исследование национальных преобразований подчеркивает неоспоримую роль технологических инноваций в формировании экономических и стратегических траекторий. Поскольку технология БПЛА является краеугольным камнем инновации, ее многогранное применение в таких областях, как национальная оборона, транспорт и сельское хозяйство, вносит значительный вклад в повышение общей конкурентоспособности страны. Таким образом, приведение технологии БПЛА в соответствие с более широкими стратегическими императивами позволит реализовать стремление к прогрессу и укреплению национальной конкурентоспособности, поддерживаемое новой парадигмой развития.

Модели глубокого обучения сыграли значительную роль в распределении задач БПЛА и планировании траектории. Общие модели глубокого обучения включают сверточные нейронные сети (CNN) [7], рекуррентные нейронные сети (RNN) [8], глубокое обучение с подкреплением (DRL) [9], генеративно-состязательные сети (GAN) [10] и трансферное обучение, каждая из которых со своими преимуществами и ограничениями. Например, CNN подходят для задач обработки изображений, но им не хватает эффективности при обработке последовательных данных [11], в то время как RNN могут обрабатывать последовательные данные, но страдают от таких проблем, как исчезновение и взрыв градиентов. DRL может выполнять задачи с отложенным вознаграждением, но требует сложного процесса обучения, в то время как GAN могут генерировать данные, но демонстрируют нестабильность во время обучения. Трансферное обучение может использовать ранее полученные знания для ускорения обучения новым задачам, но требует устранения различий в пр

Целью данного исследования является решение многомерных задач многоцелевого распределения задач БПЛА и планирования траектории с использованием адаптивного корреляционного фильтра подавления искажений (ARCF). Мы разработаем сеть ARCF, которая будет объединять состояния, действия и функции вознаграждения миссий БПЛА, чтобы обеспечить интеллектуальное принятие решений для распределения задач и планирования пути. В частности, мы будем использовать методы глубокого обучения с подкреплением для обучения сети, что позволит ей изучить оптимальные стратегии поведения БПЛА в сложных средах. В процессе обучения мы будем использовать блоки памяти воспроизведения для хранения исторического опыта и объединения целевых и оценочных сетей для повышения стабильности и эффективности процесса обучения.

Основные положения данной статьи заключаются в следующем:

- Предложить новый алгоритм совместной оптимизации адаптивного корреляционного фильтра подавления искажений (ARCF-ICO), повышающий точность и стабильность планирования миссий БПЛА.
- Интегрируйте методы многоцелевой оптимизации, обеспечивая эффективное интеллектуальное принятие решений для распределения задач БПЛА и планирования маршрута в сложных средах.

Представление экспериментальных результатов, которые показывают, что алгоритм ARCF-ICO превосходит существующие методы с точки зрения показателей AUC и точности на наборах данных UAV123 со скоростью 10 кадров в секунду и OTB-100.

2. Сопутствующие

работы 2.1. Одноцелевая оптимизация планирования траектории беспилотных летательных аппаратов

Планирование траектории беспилотных летательных аппаратов (БПЛА) по сути является задачей оптимизации, имеющей практические последствия. Ли и Дуань [12] включили стоимость угрозы и стоимость топлива в задачу взвешенной оптимизации и применили улучшенный универсальный алгоритм гравитационного поиска для повышения сходимости глобального поиска, тем самым улучшив качество оптимальных решений для траекторий БПЛА. Цюй и др. [13] объединили упрощенный оптимизатор серого волка с расширенным поиском симбиотических организмов, чтобы предложить новый гибридный алгоритм для получения возможных и эффективных маршрутов. Дасдемир и др. [14] разработа

основанный на предпочтениях одноцелевой эволюционный алгоритм для оптимизации как общего расстояния запланированных маршрутов, так и угроз радиолокационного обнаружения. Яо и др. [15] представили гибридный алгоритм, основанный на модели прогнозирующего управления и улучшенном оптимизаторе «серого волка», для планирования оптимальных траекторий сопровождения целей БПЛА в городских условиях. Папайоанну и др. [16] решили проблемы пассивного мониторинга нескольких движущихся целей в условиях препятствий с помощью БПЛА, разработав модель контроллера с прогнозирующим наведением в сочетании со стратегией совместной оценки и управления. Рен и др. [17] предложили подход многокритериального планирования пути (MOPP) с использованием генетического алгоритма сортировки без доминирования II (NSGA-II), оптимизированного как для расстояния, так и для безопасности, демонстрируя свою эффективность в городских условиях за счет использования пространственного подразделения на основе октодерев и карты индексов безопасности.

Однако текущие исследования по планированию траектории как для одного, так и для нескольких БПЛА часто фокусируются на одноцелевой оптимизации, рассматривая либо одну цель, либо объединяя несколько целей оптимизации в одну посредством линейного взвешивания. Такие подходы к оптимизации в значительной степени полагаются на субъективные весовые коэффициенты, устанавливаемые лицами, принимающими решения, которые напрямую влияют на результаты оптимизации, и могут упускать из виду траектории с выдающимися характеристиками в относительно небольших целях. В последние годы, несмотря на растущее внимание к проблемам планирования траектории на основе многокритериальной оптимизации, обычно рассматривающих только две-три оптимизированные цели, практические требования к оптимизации планирования траектории БПЛА выходят за рамки ограниченного числа целей. При решении этой проблемы создание модели планирования траектории, основанной на многомерной многокритериальной оптимизации, становится особенно важным для одновременной оптимизации различных аспектов производительности траекторий.

2.2. Многомерная многоцелевая оптимизация планирования траектории БПЛА

Многомерные задачи многокритериальной оптимизации широко распространены как в жизни, так и в инженерной практике, где несколько целей требуют одновременной оптимизации, часто с межкритериальными корреляциями, приводящими к конфликтным ситуациям. В таких случаях необходимо рассмотреть альтернативные схемы оптимизации, обеспечивающие получение эквивалентных решений. при отсутствии коррелированной информации из других схем.

Сторн и Прайс [18] предложили алгоритм дифференциальной эволюции (DE) — популяционный метод, аналогичный механизмам стационарной замены, для решения задач оптимизации с реальными параметрами. Новое потомство конкурирует только со своими соответствующими родителями, и если потомство демонстрирует лучшую приспособленность, оно заменяет его. С появлением новых биологических эвристик, таких как оптимизация роя частиц [19], алгоритм серого волка [20], алгоритм кита [21] и алгоритм поиска воробья [22], понимание того, как они применяются к различным типам задач объективной оптимизации становится решающим. В литературе оптимизировались расстояние траектории БПЛА и стоимость угрозы траектории с использованием генетических алгоритмов и сглаживались [23].

Разграничение алгоритмов многоцелевой оптимизации высокой размерности заключается в том, превышает ли количество оптимизируемых целей четыре [24]. С увеличением количества оптимизируемых целей количество недоминируемых решений, генерируемых в процессе решения алгоритмов многокритериальной оптимизации, экспоненциально увеличивается, что существенно влияет на производительность и эффективность алгоритма [25,26]. Кроме того, давление отбора, создаваемое алгоритмами многокритериальной оптимизации при решении многокритериальных задач, часто оказывается недостаточным для того, чтобы направить людей в популяции к идеальным точкам.

Стратегии улучшения этих двух показателей в основном делятся на три категории: (1) Усиление давления отбора алгоритмов путем изменения методов доминирования Парето для ускорения скорости конвергенции популяций. GrEA [27] использует метрики оценки на основе сетки для усиления давления выбора алгоритмов. NSGA-III [28] использует стратегию контрольной точки вместо стратегии расстояния скученности NSGA-II [29] для выбора отличных индивидуумов из недоминируемых решений, тем самым улучшая сходимость алгоритмов. 1by1EA [30] отбирает особей потомства одну за другой на основе индивидуальной конвергенции, когда происходит экологический отбор, а затем увеличивает разнообразие популяций с помощью нишевых методов. РПЭА [31] постоянно

генерирует серию хорошо сходящихся и распределенных контрольных точек на основе текущей численности населения для управления эволюцией. (2) Разложение сложной многомерной задачи многокритериальной оптимизации на группу подзадач и совместная оптимизация этих подзадач. MOEA [32] разлагает проблему на серию адаптивно декомпозированных подзадач одноцелевой оптимизации, а затем объединяет информацию из соседних задач. MaOEA/Ds [33] использует набор равномерно распределенных самоуправляемых эталонных векторов в пространстве, чтобы разделить пространство решений на несколько небольших подпространств и оценить достоинства отдельных лиц в подпространствах. Йи и др. [34] предложили метод многокритериальной эволюционной оптимизации, основанный на объективной декомпозиции, разлагающей проблему на несколько подзадач и решающей каждую подзадачу параллельно, полностью используя информацию других подгрупп для улучшения давления отбора недоминируемые решения. (3) Стратегия, основанная на показателях оценки. Всесторонняя оценка превосходства и неполноценности особей с помощью показателей оценки, а затем отбор отличных особей для генетических операций. Однако вычислительная сложность таких стратегий обычно высока, и такие метрики оценки обычно используются для оценки качества результатов оптимизации алгоритмов [35].

В процессе совместного планирования траектории нескольких БПЛА необходимо учитывать не только отдельные атрибуты траектории, но и пространственную координацию между несколькими БПЛА. Чтобы избежать влияния объединения нескольких целей оптимизации в одну посредством взвешивания при планировании траектории, предлагается модель, основанная на многомерной многокритериальной оптимизации, для совместного планирования траектории для нескольких БПЛА. Эта модель оптимизирует стоимость расстояния траектории БПЛА, стоимость безопасности траектории, стоимость энергии траектории и пространственную координацию между несколькими БПЛА в качестве целей оптимизации. В отличие от существующих подходов, которые рассматривают траекторию одного БПЛА как отдельного человека в популяции и оптимизируют траектории нескольких БПЛА отдельно, в этой модели траектории нескольких БПЛА рассматриваются как единое целое в популяции, и оптимизация выполняется одновременно на нескольких траекториях БПЛА. Кроме того, проводятся всесторонние оценки конвергенции и разнообразия особей в популяции, а стратегии спаривания алгоритма для задач планирования траектории улучшаются для повышения производительности конвергенции [35,36]. С помощью алгоритма получается набор оптимальных по Парето траекторий для нескольких БПЛА, которые могут использовать лица, принимающие решения. Лица, принимающие решения, могут выбрать наиболее подходящие траектории для своих атрибутов миссии из этого набора оптимальных траекторий.

3. Моделирование планирования траектории полета нескольких БПЛА 3.1.

Описание проблемы В контексте совместного планирования траектории нескольких беспилотных летательных аппаратов (БПЛА) группе БПЛА поручено перемещаться от нескольких отправных точек к ряду заданных целевых точек для выполнения сложных миссий. Сценарий миссии разворачивается на территории, защищенной различными системами защиты, где БПЛА должны ловко уклоняться от угроз в зонах радиолокационного покрытия противника и зонах зенитного огня, принимая во внимание ограничения производительности и требования взаимодействия каждого БПЛА. На основе этого сценария мы проводим имитационный анализ навигации группы БПЛА и траекторий выполнения миссии в трехмерном пространстве. Вычислительные предположения заключаются в следующем:

(1) Все БПЛА поддерживают постоянную скорость полета во время выполнения миссии. (2) Каждый участок траектории разделен на прямые траектории полета. (3) Каждый БПЛА обладает идентичными летно-техническими характеристиками.

В основе совместного планирования траектории нескольких БПЛА лежит разработка моделей стоимости траектории и совместных пространственных моделей. Стоимость траектории в первую очередь учитывает расстояние, угрозу и потребление энергии. Цель модели — минимизировать эти затраты при одновременном улучшении пространственной координации между БПЛА.

Предполагая, что имеется N_z целевых точек, каждая из которых требует задач разведки, удара и подтверждения, представленных как Sm_j , где $j \in [1, N_z]$ обозначает m -й тип задачи j -й целевой точки, соответствующий разведке, удару и подтверждению ($m = 1, 2, 3$). Отсюда общее количество задач равно $\sum_{j=1}^{N_z} m_j$. У каждой задачи есть определенные временные окна $[c_{mn}, d_{mn}]$, а обозначенная потребность в боеприпасах z_j для ударных задач в каждой целевой точке.

Группа БПЛА состоит из разведывательных БПЛА N_r , ударных БПЛА N_q и разведывательно-ударных БПЛА N_{rq} , всего $N_v = N_r + N_q + N_{rq}$ БПЛА, индексированных как $u \in [1, N_v]$. Каждый БПЛА u имеет вектор возможностей $Capability_u$, соответствующий его типу задачи, где $Capability_u(m)$ представляет способность БПЛА u выполнять задачу типа m , принимая значения 1 или 0. Грузоподъемность каждого БПЛА u равна z_u , и если БПЛА u не обладает ударной способностью, тогда $z_u = 0$. Предполагается, что связь между расходом топлива f_{ru} и скоростью полета V_u каждого БПЛА u равна $f_{ru} = \alpha_u \times V_u$, где α представляет собой пропорциональность между расходом топлива и скоростью полета, а V_u находится в диапазоне $[k_u, j_u]$, обозначающем минимальную и максимальную скорости.

В городских условиях проблема отслеживания несколькими БПЛА нескольких наземных целей изображена на рисунке 1, где N БПЛА готовы выполнять M задач. Набор БПЛА обозначается как $U = \{U_1, U_2, \dots, U_N\}$, а целевое множество обозначается как $H = \{H_1, H_2, \dots, H_M\}$, причем типы задач обозначаются $M_i = \{1, 2\}$ ($M_i = 1$ для разведки, $M_i = 2$ для удара).

Чтобы продемонстрировать неоднородность БПЛА и конкретные требования к производительности сценариев миссии, Z_{um} используется для представления матрицы производительности БПЛА, где элементы матрицы представляют способность БПЛА выполнять определенную задачу. Например, если имеется три БПЛА и их матрица производительности Z_{um} показана в таблице 1, $Z_{um}(1, 1) = 0,9$ указывает, что возможности БПЛА 1 по разведывательным задачам равны 0,9. Если H_1 — разведывательная задача ($M_1 = 1$) с минимальным требованием возможностей 0,6, то среди трех БПЛА U_1, U_2, U_3 только U_1 (0,9) может удовлетворить требованиям задачи H_1 .

Таблица 1. Значение возможностей БПЛА.

Беспилотный летательный аппарат	Значение способности	
	Скаут	Отслеживать
U1	0,9	0,4
U2	0,3	0,9
U3	0,5	0,5




Рисунок 1. Распределение задач для нескольких БПЛА в городских сценариях.

3.2. Модель целей оптимизации проектирования

Наша цель — минимизировать общий расход топлива всего парка БПЛА при выполнении задач, при этом максимизируя эффективность выполнения задач. Поэтому мы определим следующие функции стоимости.

Общая стоимость потребления топлива: представляет собой общий расход топлива БПЛА с момента взлета, выполнения задачи и возвращения в аэропорт. Расход топлива каждого БПЛА зависит от дальности полета и скорости. Если мы определим расход топлива БПЛА u , выполняющего задачу k от точки P_i до P_j , как $f_{u,k,i,j}$, то общий расход топлива F_{fuel} можно выразить как

$$F_{fuel} = \sum_{u=1}^{N_u} \sum_{k=1}^{N_k} \sum_{i=0}^{N_p} \sum_{j=1}^{N_p} f_{u,k,i,j} \cdot \delta_{u,k,i,j}$$

(1)

Стоимость соответствия времени задачи: измеряет разницу между временем выполнения задач и серединой их временных окон. Цель – сделать задачу БПЛА

время выполнения как можно ближе к середине временных окон задачи. Если мы обозначим пригодность БПЛА u во временном окне как $T_{adapt,u}$, то общая пригодность временного окна F_{time} будет равна

$$F_{\text{время}} = \sum_{i=1}^{N_u} T_{\text{адапт},u} = \sum_{i=1}^{N_u} \sum_{j=0}^{N_p-1} \sum_{k=1}^3 X_{u,k,i,j} \cdot (t_{u,k,i,j}) \cdot \frac{s_{k,j} + e_{k,j}}{2} \quad (2)$$

Объединив две вышеупомянутые функции стоимости, мы формируем задачу двухцелевой оптимизации:

$$\text{Минимизировать } F = \alpha \cdot F_{\text{fuel}} + \beta \cdot F_{\text{time}} \quad (3)$$

где α и β — параметры, которые уравнивают важность двух целей. В уравнении (3) целевые функции нормализованы, чтобы гарантировать, что каждая из них вносит равный вклад в общую оптимизацию. Процесс нормализации включает масштабирование каждой целевой функции до диапазона $[0, 1]$ на основе их соответствующих максимальных и минимальных значений, наблюдаемых во время начальных запусков.

3.3. Ограничения

В задаче планирования траектории БПЛА мы должны учитывать следующие ограничения, включая погодные условия для учета операций на малой высоте.

Ограничение выполнения задачи: убедитесь, что каждая задача выполняется хотя бы одним БПЛА с соответствующая способность. Формула ограничения на выполнение задачи выглядит следующим образом:

$$\sum_{i=1}^{N_u} X_{u,k,i,j} \geq 1, \quad k, i, j \quad (4)$$

Здесь $X_{u,k,i,j}$ представляет собой двоичную переменную решения, указывающую, выполняет ли БПЛА u задачу k от точки P_i до P_j . N_u — общее количество БПЛА. k представляет тип задачи. i представляет индекс отправной точки. j представляет индекс конечной точки.

Ограничение соответствия возможностей: задачи, выполняемые БПЛА, должны соответствовать ограничениям их возможностей. Формула ограничения для сопоставления возможностей выглядит следующим образом:

$$\sum_{i=1}^{N_u} X_{u,k,i,j} \leq C_{\text{возможности},k,u}, \quad k, i, j \quad (5)$$

где $C_{\text{возможности},k,u}$ представляет собой способность БПЛА u выполнять задачу k .

Ограничения по погодным условиям: на операции на малых высотах влияют такие погодные условия, как скорость ветра, осадки и видимость. Эти факторы учитываются при оценке траектории для обеспечения безопасных и надежных операций. Формула ограничения для погодных условий выглядит следующим образом:

$$W_{u,k,i,j} \leq W_{\text{max}}, \quad u, k, i, j \quad (6)$$

где $W_{u,k,i,j}$ представляет воздействие погоды на БПЛА u при выполнении задачи k от точки P_i до P_j . W_{max} — максимально допустимое погодное воздействие.

Ограничение времени полета: убедитесь, что время полета БПЛА от одной точки задания к другой не превышает заданное максимальное значение. Формула ограничения для времени полета выглядит следующим образом:

$$t_{u,k,i,j} \leq t_{\text{max}}, \quad u, k, i, j > 1, \text{ где} \quad (7)$$

$t_{u,k,i,j}$ представляет время, в которое БПЛА u достигает задания точку j при выполнении задачи k , начиная с точки P_i . t_{max} — максимально допустимое время полета между последовательными точками задачи.

3.4. Показатели

производительности Оценка производительности имеет решающее значение для подтверждения эффективности нашей модели оптимизации. Мы используем следующие показатели производительности:

Охват задач: отношение успешно назначенных и выполненных задач к общему количеству задач. Покрытие задачи можно выразить как

$$\text{Охват} = \frac{\text{Количество успешно поставленных и выполненных задач}}{\text{Общее количество задач}} \quad (8)$$

Среднее потребление батареи: Среднее потребление батареи при формировании БПЛА. для выполнения всех задач выражается следующим образом:

$$\text{Среднее потребление батареи} = \frac{\sum_{i=1}^{N_u} \text{Используемая вами батарея}}{N_u} \quad (9)$$

Endurance: Endurance измеряет время работы БПЛА, гарантируя, что они могут выполнять задачи в пределах заряда батареи. Это выражается как

$$\text{Выносливость} = \frac{\sum_{i=1}^{N_u} \text{Время работы вас}}{N_u} \quad (10)$$

Эффективность времени: разница между временем выполнения всех задач и временем выполнения. самое раннее время начала. Это может быть выражено как

$$\text{Эффективность времени} = \max_{u \in U} \{t_{\text{completion}, u}\} - \min_{u \in U} \{t_{\text{start}, u}\} \quad (11)$$

С помощью этих показателей производительности мы можем всесторонне оценить эффективность алгоритма оптимизации, что позволяет осуществлять дальнейшую корректировку параметров модели или усовершенствование алгоритма.

4. Алгоритм адаптивной генетической многоцелевой оценки. Алгоритм

ARCF (адаптивный фильтр коррекции карты ответов) направлен на интеграцию искажений карты ответов, возникающих в процессе отслеживания, с процессом обучения фильтра, тем самым повышая производительность алгоритма (как показано на рисунке 2).). Чтобы подавить искажение карты ответа, первым шагом является идентификация искажения (т. е. определение момента возникновения искажения карты ответа). Он вводит евклидову норму для определения разницы между картами ответов предыдущего кадра M1 и текущего кадра M2.




Рисунок 2. Блок-схема алгоритма ARCF.

Основная цель алгоритма ARCF — объединить искажение карты отклика, генерируемое во время отслеживания цели, с процессом обучения фильтра, повышая производительность отслеживания за счет динамического обновления фильтра. Искажение карты реакции в первую очередь вызвано быстрым движением цели или внешними факторами окружающей среды, такими как окклюзия и изменения освещенности. Алгоритм ARCF идентифицирует и подавляет эти искажения, анализируя изменения в картах ответов между последовательными кадрами, в частности, вычисляя евклидово расстояние между картами ответов двух кадров.

В алгоритме карты откликов двух последовательных кадров F1 и F2 обозначаются как M1 и M2 соответственно и выравниваются с помощью операции сдвига ψ для вычисления их разностей. Формула расчета разницы:

$$M = \psi(M1, M2) = \frac{(M1[p, q] - M2[p, q])^2}{n, d} \tag{12}$$

Здесь p и q представляют собой пространственные координаты карты ответа. На основании вышеупомянутой меры различия целевую функцию алгоритма ARCF можно описать как задачу оптимизации, направленную на минимизацию искажения карты ответа при одновременном максимизации точности отслеживания цели. Целевая функция состоит из члена искажения и члена регуляризации, выражаемого как

$$\min_{\text{час}} \lambda \|h\|^2 + \gamma \sum_{d=1}^D \|h - M_d - Y_d\|^2 + \epsilon \|M\| \tag{13}$$

где h — фильтр, * обозначает операцию свертки, Md — карта входного ответа для d-го канала, Yd — желаемая карта выходного ответа, а λ , γ и ϵ — коэффициенты, регулирующие важность каждого термина.

Для повышения эффективности вычислений целевая функция дополнительно преобразуется в частотная область. В частотной области формула принимает вид

$$\min_{\text{час}} \lambda \|H\|^2 + \gamma \sum F(H) X Y + \epsilon \|M\| \tag{14}$$

где F представляет преобразование Фурье, $\odot$ обозначает поэлементное умножение, а X и Y — входное и желаемое выходное представления в частотной области соответственно.

Используя алгоритм ADMM (метод множителей чередующегося направления) для решения задачи оптимизации, фильтр можно эффективно обновлять. Процесс решения включает в себя две основные подзадачи: оптимизацию фильтра и обновление карты ответов. Этот подход эффективно подавляет искажения карты отклика, вызванные быстрым движением или внешними изменениями окружающей среды, тем самым повышая стабильность и точность алгоритма отслеживания. Алгоритм ARCF можно резюмировать как Алгоритм 1.

Алгоритм 1: Процедура ARCF

Инициализируйте фильтр h0, скорость обучения λ , γ , ϵ
Установите максимальное количество
итераций T для t = 1 на T do

Захватить текущий кадр Ft
Вычислите карту ответа Mt, используя ht-1,
если t > 1, то

Вычислить искажение $M = \frac{(M_t[p, q] - M_{t-1}[p, q])^2}{2}$

конец, если

Обновить фильтр в частотной области:
 $H_t = \arg \min_H \lambda \|H\|^2 + \gamma \sum F(H) X_t Y_t + \epsilon \|M\|$
Обновить карту ответа Mt :
 $M_t = H_t \odot F_t$
Проверка сходимости:
если $|F(H_t) - F(H_{t-1})| < \text{порог}$, то

сломать

конец, если

Обновите ht, указав Ht в конце пространственной области для

Выведите лучшее глобальное решение Gbest = hT

4.1. Алгоритм ARCF-ICO

Алгоритм ARCF-ICO объединяет значительные улучшения исходной стратегии ARCF, уделяя особое внимание как сходимости, так и разнообразию решений в многомерном пространстве оптимизации. Это особенно актуально в контексте планирования миссий БПЛА, где разнообразные оперативные условия и быстро меняющиеся требования к миссиям требуют надежного и адаптивного подхода к оптимизации.

На начальном этапе алгоритма ARCF-ICO приоритет отдается достижению высоких показателей конвергенции. Это обеспечивает быстрое выравнивание БПЛА по оптимальным траекториям или наборам решений, эффективно удовлетворяя неотложные оперативные потребности, такие как наблюдение или обнаружение угроз. По мере развития алгоритма акцент смещается в сторону сохранения разнообразия решений. Это имеет решающее значение в операциях БПЛА для изучения ряда потенциальных траекторий полета или тактических стратегий, тем самым избегая локальных оптимумов и повышая надежность результатов миссии. Алгоритм ARCF-ICO предназначен для реализации различными категориями БПЛА, включая самолеты, винтокрылые и гибридные БПЛА. Эти БПЛА могут использоваться как в коммерческих, так и в военных целях, в зависимости от их возможностей и требований миссии.

Индикатор комплексной оценки конвергенции и разнообразия (CAD) [37] — это недавно предложенный показатель, предназначенный для оценки как конвергенции, так и разнообразия решений в рамках нашей структуры ARCF-ICO. Этот новый показатель определяется следующим образом:

$$CAD(ui, U) = 1 + \text{rand}(0, 8, 1) \times M \times \frac{\tau}{\tau_{\max}}^\theta \times D(ui, U) \times (1 - C(ui, U)) \quad (15)$$

где $D(ui, U)$ представляет собой меру разнообразия, а $C(ui, U)$ обозначает меру конвергенции для БПЛА ui в парке U . Параметр M обозначает количество целей, а θ определяет баланс между конвергенцией и разнообразием, поскольку Алгоритм выполняет итерации от t до $t_{\max}$ — максимального количества поколений.

Разнообразие $D(ui, U)$ вычисляется как

$$SDE(ui, U) = \min_{ui, U, j} \sqrt{\sum_{k=1}^M sde(f_k(ui, U), f_k(u_j, U))^2} \quad (16)$$

где $sde(f_k(ui, U), f_k(u_j, U))$ определяется как:

$$sde(f_k(ui, U), f_k(u_j, U)) = \begin{cases} |f_k(u_j, U) - f_k(ui, U)| & \text{если } |f_k(u_j, U) - f_k(ui, U)| > f_k(u_j, U) \\ 0 & \text{противном случае} \end{cases} \quad (17)$$

Сходимость $C(ui, U)$ БПЛА по отношению к парку определяется количественно как

$$C(ui, U) = \frac{\text{Диск}(ui, U)}{M} \quad (18)$$

где $\text{Диск}(ui, U)$ представляет собой евклидово расстояние от БПЛА ui до идеального решения в нормализованном объективном пространстве.

Интегрируя эти стратегии, ARCF-ICO динамически адаптирует планирование миссий БПЛА и тактику реагирования в соответствии с меняющимися условиями окружающей среды и оперативными требованиями, оптимизируя как эффективность, так и результативность развернутых БПЛА.

4.2. Многоцелевое планирование ARCF-ICO

В модели многоцелевой оптимизации ARCF-ICO мы разработали эффективную стратегию сопряжения, адаптированную для сложных задач, с которыми сталкиваются БПЛА. Эта стратегия сочетает в себе благоприятные черты особей внутри популяции и вводит стохастические элементы для увеличения разнообразия популяции, тем самым повышая адаптивность и гибкость алгоритма. Алгоритм ARCF-ICO применим к миссиям, выполняемым в условиях прямой видимости (VLOS) [38], за пределами прямой видимости (BVLOS) [39].

автономные операции. Гибкость алгоритма позволяет ему адаптироваться к различным эксплуатационным ограничениям и требованиям.

В контексте планирования траектории БПЛА точки траектории, генерируемые каждым БПЛА для каждого участка траектории представлены следующей матрицей:

$$X = [X_1, X_2, \dots, X_M]^T \quad (19)$$

где X_i — матрица размера $N \times 3L$, представляющая i -го человека в популяции, N — количество БПЛА, а L — количество сегментов траектории.

В процессе спаривания в родительской популяции два родителя P_1 и P_2 выбираются на основе их комплексного показателя оценки CAD. Формула расчета CAD выглядит следующим образом:

$$CAD(P) = \frac{1}{N} \sum_{j=1}^N \frac{1 + \text{rand}(0,8, 1) \times M \times \frac{\tau}{t_{\max}} \times D(P_i, P) \times (1 - C(P_i, P))}{\theta} \quad (20)$$

где $D(P_i, P)$ и $C(P_i, P)$ представляют показатели разнообразия и конвергенции отдельных P_i , M — количество целевых функций, θ — параметр баланса, t — текущее поколение, $t_{\max}$ — максимальное поколение.

Операция спаривания заключается в следующем: информация о траекториях двух родителей объединяется для создания новых траекторий потомства:

$$P_{\text{new},j} = \alpha P_{1,j} + (1 - \alpha) P_{2,j}, \quad \text{где} \quad (21)$$

$P_{1,j}$ и $P_{2,j}$ обозначают координаты положения родителей P_1 и P_2 в j -й точке траектории соответственно, а α — случайное число от 0 до 1 используется для контроля соотношения вкладов двух родителей в вновь созданное потомство. Индивидуальная операция сопряжения показана на рисунке 3.




Рисунок 3. Индивидуальная операция спаривания.

Такая конструкция гарантирует, что БПЛА могут корректировать свои стратегии полета в соответствии с фактическими требованиями задачи и изменениями окружающей среды при выполнении таких задач, как наблюдение, разведка или другие сложные задачи. Кроме того, подход многокритериальной оптимизации позволяет БПЛА оптимизировать другие важные показатели задач, такие как время полета и топливная экономичность, обеспечивая при этом эффективность задач, тем самым гарантируя комплексное и высокопроизводительное выполнение миссии.

5. Моделирование и анализ результатов 5.1.

Наборы данных

Чтобы всесторонне оценить производительность алгоритма, мы используем два широко используемых набора данных: набор данных UAV123@10fps [39] и набор данных OTB-100 [40]. Ниже приведены подробные сведения о каждом наборе данных:

Набор данных UAV123 со скоростью 10 кадров в секунду. Этот набор данных включает 123 сценария отслеживания, снятые с использованием БПЛА в воздушной среде. Он включает в себя смесь реальных и синтетических сцен, созданных с помощью симуляторов. Набор данных охватывает 12 различных условий отслеживания, предоставляя разнообразный набор сценариев для оценки.

Набор данных OTB-100: Набор данных OTB-100 состоит из 100 реальных сценариев отслеживания, собранных вручную. Он включает в себя 11 различных сред отслеживания задач, предлагая широкий спектр сценариев для оценки производительности алгоритма.

Использование этих наборов данных позволяет провести комплексную оценку алгоритма. в различных условиях отслеживания и условий окружающей среды. Его конкретная информация показано в Таблице 2 ниже.

Таблица 2. БПЛА UAV123 со скоростью 10 кадров в секунду и подробности набора данных ОТВ-100.

БПЛА123@10 кадров в секунду			ОТВ-100	
Серийный номер	Название соревнования	Число	Название соревнования	Число
1	Изменение масштаба (SV)	109	Изменение масштаба (SV)	65
2	Изменение соотношения сторон (ARC)	68	Окклюзия (ОКС)	49
3	Фоновый беспорядок (BC)	21	Вариант освещения (IV)	38
4	Движение камеры (CM)	70	Размытие в движении (MB)	31
5	Быстрое движение (FM)	28	Деформация (DEF)	43
6	Полная окклюзия (FOC)	33	Быстрое движение (FM)	43
7	Вариант освещения (IV)	31	Внеплоскостное вращение (OPR)	64
8	Низкое разрешение (LR)	48	Вращение в плоскости (IPR)	52
9	Вне поля зрения (OV)	30	Фоновые помехи (BC)	33
10	Частичная окклюзия (POC)	73	Вне поля зрения (OV)	14
11	Аналогичный объект (SOB)	39	Низкое разрешение (LR)	10
12	Изменение точки зрения (VC)	60	-	-

5.2. Экспериментальная установка параметров

При постановке экспериментов используемая аппаратная конфигурация включает в себя процессор Intel Core i9-13700 и 32 Гб памяти. Конфигурация программного обеспечения на базе платформы MATLAB R2019a. Что касается настроек параметров, то регуляризация Параметр установлен на 1,2, следуя настройкам исходного алгоритма ARCF. После экспериментальных корректировок, другой параметр регуляризации установлен на 0,001. Обучение ставка для целевого шаблона, обозначенная η , установлена на 0,0192, снова следуя рекомендациям из исходного алгоритма ARCF.

5.3. Индексы оценки корреляции

Для алгоритма многоцелевой оптимизации ARCF-ICO при планировании миссий БПЛА: мы используем три улучшенных показателя оценки для комплексной оценки производительности алгоритма : площадь под кривой (AUC), ошибка местоположения центра (CLE) и точность. Эти метрики эффективно оценивают производительность и точность БПЛА во время выполнения миссии.

Площадь под кривой (AUC): этот показатель оценивает общий уровень успеха БПЛА. при выполнении множества полетных задач, особенно при поддержании целевых целей в сложных условиях . AUC рассчитывается как

$$AUC = \frac{\text{площадь} (B_{pred} \quad B_{true})}{\text{площадь}(B_{pred} \quad B_{true})}, \tag{22}$$

где B_{pred} представляет прямоугольник прогнозируемого местоположения цели с помощью алгоритма БПЛА, и B_{true} представляет прямоугольник истинного целевого местоположения.

Ошибка местоположения центра (CLE): этот показатель измеряет среднее евклидово расстояние. между прогнозируемым центральным положением БПЛА и истинным центральным положением цели. Высокая точность CLE необходима для обеспечения точного выполнения таких задач, как мониторинг. и разведка. CLE рассчитывается как

$$CLE = \sqrt{(x_{pred} - x_{true})^2 + (y_{пред} - \text{верно})^2}, \tag{23}$$

где $(x_{pred}, y_{пред})$ — прогнозируемое центральное положение БПЛА, а (x_{true}, y_{true}) — истинное центральное положение мишени.

Точность: Точность измеряет точность локализации БПЛА в пределах определенного порога t , то есть долю кадров, в которых ошибка прогнозирования центрального положения цели находится в пределах порога. Это критический показатель для оценки эффективности отслеживания БПЛА в реальном времени. Точность рассчитывается как

$$\text{Точность} = \frac{N_t \text{ порог}}{\text{Всего}}, \tag{24}$$

где N_t threshold — это количество кадров, где CLE меньше или равно порогу t , а N_{total} — общее количество кадров. Порог t обычно устанавливается равным 20 пикселям.

С помощью этих трех показателей оценки можно всесторонне оценить эффективность БПЛА при выполнении задач в сложных условиях, таких как точность и стабильность планирования траектории. Эти показатели не только помогают оптимизировать стратегии эксплуатации БПЛА, но также обеспечивают важную обратную связь для дальнейшего улучшения алгоритмов и корректировки параметров полета.

5.4. Сравнительное

исследование В этой главе алгоритм ARCF-ICO оценивается с использованием двух наборов данных: UAV123 при 10 кадрах в секунду и ОТВ-100. Чтобы лучше понять производительность предлагаемого алгоритма ARCF-ICO, его сравним с восемью популярными алгоритмами в области отслеживания видеообъектов, включая KCF [41], LDES [42], MCCT-H [43], Staple [44], fDSST [45] и AutoTrack [46]. Алгоритмы LDES и AutoTrack были опубликованы в AAAI2019 и CVPR2020 соответственно с упором на наборы данных БПЛА, а остальные пять алгоритмов представляют собой классические алгоритмы отслеживания на основе корреляционных фильтров последних лет.

На рисунке 4 показано всестороннее сравнение алгоритма ARCF-ICO с другими шестью основными алгоритмами в наборе данных UAV123 при 10 кадрах в секунду с точки зрения AUC и точности. Из рисунка видно, что предлагаемый алгоритм ARCF-ICO достигает наивысшей производительности с комплексным AUC 0,516 и комплексной точностью 0,712, превосходя остальные шесть алгоритмов. Алгоритмы AutoTrack и LDES занимают второе и третье места с комплексными значениями AUC 0,504 и 0,492 и комплексными значениями точности 0,682 и 0,655 соответственно. По сравнению с алгоритмом ARCF-ICO алгоритмы AutoTrack и ARCF имеют меньшую AUC на 1,2% и 2,4%, а также меньшую точность на 3,0% и 5,7% соответственно. Остальные пять алгоритмов, MCCT-H, Staple, fDSST и KCF, имеют более низкие значения AUC в диапазоне от 0,285 до 0,456 и более низкие значения точности в диапазоне от 0,384 до 0,581 по сравнению с алгоритмом ARCF-ICO.




Рисунок 4. Сравнение AUC и Precision в наборе данных UAV123 при 10 кадрах в секунду.

В таблице 3 представлено всестороннее сравнение точности различных алгоритмов в 12 сложных условиях набора данных UAV123 со скоростью 10 кадров в секунду. Из таблицы 3 видно, что алгоритм ARCF-ICO неизменно занимает первое место по точности во всех 12 сложных средах. Алгоритмы AutoTrack и LDES занимают второе место в десяти и двух сложных условиях соответственно. Таким образом, результаты сравнения из таблицы 3 демонстрируют, что алгоритм ARCF-ICO хорошо адаптируется к наиболее сложным задачам отслеживания и демонстрирует надежную производительность отслеживания.

Таблица 3. Таблица сравнения точности UAV123 со скоростью 10 кадров в секунду для различных сценариев задач набора данных.

Название соревнования	Наш алгоритм			Контрастный алгоритм			
	ARCF-ICO	AutoTrack	LDES	MCCT-H	fDSST	Скоба	KCF
CB	0,724	0,672	0,642	0,545	0,521	0,496	0,372
APK	0,692	0,686	0,631	0,591	0,552	0,503	0,336
Движение	0,702	0,621	0,603	0,503	0,521	0,467	0,415
CM	0,684	0,691	0,633	0,512	0,488	0,472	0,375
ФМ	0,696	0,664	0,628	0,498	0,508	0,475	0,311
ФОК	0,693	0,677	0,689	0,582	0,571	0,436	0,388
IV	0,669	0,673	0,642	0,603	0,598	0,479	0,406
ЛР	0,688	0,645	0,667	0,654	0,635	0,527	0,416
ОВ	0,741	0,714	0,656	0,672	0,626	0,426	0,403
РОС	0,744	0,725	0,702	0,625	0,645	0,539	0,369
СОБ	0,752	0,714	0,693	0,564	0,586	0,545	0,388
ВК	0,763	0,702	0,671	0,625	0,645	0,535	0,426

В таблице 4 показаны сравнительные результаты комплексного измерения точности различных алгоритмов в 11 сложных средах в наборе данных ОТВ-100. Из таблицы 4 видно, что что алгоритм ARCF-ICO занимает первое место по точности во всех 11 средах, при этом Алгоритмы AutoTrack и LDES занимают второе место в пяти и трех средах соответственно. Кроме того, алгоритмы MCCT-H и Staple занимают второе место в рейтинге Fast Motion. и проблемы внеплоскостного вращения соответственно. Следовательно, результат сравнения Таблица 4 дополнительно подтверждает эффективность алгоритма ARCF-ICO.

Таблица 4. Таблица сравнения точности ОТВ-100 для различных сценариев обработки набора данных.

Название соревнования	Наш алгоритм			Контрастный алгоритм			
	ARCF-ICO	AutoTrack	LDES	MCCT-H	fDSST	Скоба	KCF
ФМ	0,517	0,485	0,497	0,505	0,422	0,388	0,263
Движение	0,483	0,476	0,496	0,476	0,412	0,433	0,314
МБ	0,514	0,502	0,467	0,443	0,402	0,367	0,278
ДЕФ	0,482	0,477	0,472	0,425	0,378	0,336	0,266
IV	0,541	0,538	0,533	0,501	0,445	0,388	0,325
Сканирование	0,477	0,432	0,375	0,468	0,305	0,325	0,213
ЛР	0,533	0,532	0,596	0,492	0,462	0,439	0,306
ОКК	0,488	0,482	0,457	0,426	0,430	0,422	0,239
ОПР	0,563	0,552	0,512	0,423	0,458	0,563	0,325
ОВ	0,534	0,529	0,505	0,412	0,433	0,368	0,336
СВ	0,545	0,537	0,546	0,447	0,448	0,392	0,268

5.5. Визуализация моделирования

На рисунке 5 показаны результаты распределения задач, полученные с помощью алгоритма ARCF-ICO. демонстрация того, что эта проблема динамического распределения по сути является нелинейным программированием задача с оптимальными решениями. На левой панели рисунка 5 показаны решения Парето для распределения задач БПЛА и планирования траектории, полученного на основе набора данных UAV123 при 10 кадрах в секунду, а на правой панели представлены решения из набора данных ОТВ-100. Фронт Парето в обе панели указывают на компромиссы между различными целями, демонстрируя эффективность и эффективность алгоритма ARCF-ICO при многокритериальной оптимизации. В Кроме того, мы также показываем результаты постановки задачи моделирования MATLAB для 10 БПЛА в

Рисунок 6. Как видно из рисунка 6г, 10 БПЛА собираются найти соответствующий целевой объект.




Рисунок 5. Постановка задачи решения алгоритма ARCF-ICO. Решения Парето для распределения задач БПЛА и планирования траектории, полученные на основе набора данных UAV123 при 10 кадрах в секунду (слева) и набора данных ОТБ-100 (справа).




Рисунок 6. Демонстрация назначения задачи моделирования MATLAB для 10 БПЛА. а) исходное состояние БПЛА; (b,c) Промежуточный статус задания БПЛА; (d) Окончательный статус назначения БПЛА.

Кроме того, проводятся симуляционные испытания на сценах из набора данных ОТБ-100. Карта среды разделена на пять подкарт, но использование одного только алгоритма ARCF-ICO для планирования траектории БПЛА не может обеспечить максимальную скорость обучения модели. Это может быть связано с непрерывным процессом обучения исходного алгоритма ARCF в окружающей среде методом проб и ошибок, который требует больше времени. На рисунке 7 показано планирование траектории задач БПЛА на кадрированных картах окружающей среды набора данных ОТБ-100 с использованием алгоритма ARCF-ICO.




Рисунок 7. Алгоритм ARCF-ICO продемонстрирован на карте среды посевоов набора данных ОТБ-100 для планирования миссий БПЛА. Синяя точка представляет время обучения для каждого алгоритма.

6. Выводы и обсуждение.

В этом исследовании представлен алгоритм ARCF-ICO для решения многоцелевой оптимизации при планировании миссий БПЛА, повышающий производительность отслеживания БПЛА в сложных средах. Сосредоточив внимание как на конвергенции, так и на разнообразии, алгоритм ARCF-ICO адаптируется к быстрым изменениям окружающей среды и динамичным требованиям миссий посредством обновлений фильтров в реальном времени. Проверка с использованием наборов данных UAV123@10fps и OTB-100 демонстрирует, что алгоритм ARCF-ICO превосходит существующие методы по метрикам AUC и Precision, что указывает на превосходную точность и надежность отслеживания. Однако выявлены два основных ограничения: неоптимальная производительность алгоритма при работе с чрезвычайно высокоскоростными динамическими целями и необходимость повышения эффективности вычислений. Будущие исследования будут направлены на изучение более эффективных алгоритмических структур для снижения потребления вычислительных ресурсов и оптимизации реакции на высокоскоростные движущиеся цели. В целом, алгоритм ARCF-ICO предлагает значительный технологический прогресс для многоцелевой оптимизации БПЛА, обеспечивая значительную теоретическую и практическую ценность как для гражданских, так и для военных приложений.

Вклад автора: концептуализация, методология, написание — подготовка оригинального проекта, визуализация и контроль: ZZ (Zijie Zheng). Валидация, формальный анализ и расследование: ZZ (Чжицзюнь Чжан). Программное обеспечение, проверка, написание — обзор и редактирование: ZL Ресурсы, обработка данных, написание — обзор и редактирование: QY Проверка, формальный анализ и методология: YJ Все авторы прочитали и согласились с опубликованной версией рукописи.

Финансирование: Данное исследование не получило внешнего финансирования.

Заявление о доступности данных: Адрес загрузки набора данных UAV123: <https://cemse.kaust.edu.sa/ivul/> БПЛА 123 (по состоянию на 10 марта 2024 г.). Адрес загрузки набора данных OTB: http://cvlab.hanyang.ac.kr/tracker_benchmark/datasets.html (по состоянию на 10 марта 2024 г.). Код, подтверждающий результаты этого исследования, не является общедоступным, но его можно получить у соответствующего автора по обоснованному запросу.

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Рекомендации

1. Чен Дж.; Чжан, Ю.; Ву, Л.; Вы т.; Нин, Х. Алгоритм на основе адаптивной кластеризации для автоматического планирования пути гетерогенных БПЛА. IEEE Транс. Интел. Трансп. Сист. 2021, 23, 16842–16853. [\[Перекрестная ссылка\]](#)

2. Чен Дж.; Линг, Ф.; Чжан, Ю.; Вы т.; Лю, Ю.; Ду, Х. Планирование маршрутов покрытия гетерогенных беспилотных летательных аппаратов на основе система колоний муравьев. Рой Эвол. Вычислить. 2022, 69, 101005. [\[CrossRef\]](#)

3. Чен Дж.; Ли, Т.; Чжан, Ю.; Вы т.; Лу, Ю.; Тивари, П.; Кумар, Н. Обучение с подкреплением на основе глобального и локального внимания для совместного управления поведением нескольких БПЛА. IEEE Транс. Вех. Технол. 2024, 73, 4194–4206. [\[Перекрестная ссылка\]](#)

4. Нин, Х.; Тиан, В.; Он, Ф.; Бай, Х.; Сан, Л.; Ли, В. Модель нейрона с функцией покрытия «Гиперколбаса» и алгоритм обучения для классификация изображений. Распознавание образов. 2023, 136, 109216. [\[CrossRef\]](#)

5. Яо, Ю.; Лю, З. Новая концепция развития способствует ускорению формирования нового качества производительности: теоретическая логика и пути реализации. Дж. Сианьский университет. Финанс. Экон. 2024, 37, 3–14.

6. Ма, Г.; Чен, Х. От финансовой мощи к финансовой мощи: международные сравнения и подход Китая. Дж. Сианьский университет. Финанс. Экон. 2024, 37, 46–59.

7. Ван Дж.; Ли, Ф.; Любой.; Чжан, Х.; Сан, Х. На пути к надежному слиянию LiDAR-камеры в пространстве BEV посредством взаимного деформируемого внимания и временная агрегация. IEEE Транс. Сист. Целей. Видео Технол. 2024, 34, 5753–5764. [\[Перекрестная ссылка\]](#)

8. Чен, СС; Вэй, СС; Чен, С.Х.; Вэ, ЛМ; Лин, Его Святейшество ИИ спрогнозировал модель компетенций для максимизации производительности труда. Киберн. Сист. 2022, 53, 298–317. [\[Перекрестная ссылка\]](#)

9. Кауфманн Э.; Бауэрсфельд, Л.; Локерсио, А.; Мюллер, М.; Колтун В.; Скарамуцца, Д. Гонки дронов чемпионского уровня с использованием глубокого обучения с подкреплением. Природа 2023, 620, 982–987. [\[Перекрестная ссылка\]](#)

10. Утамакумаран, А. Обнаружение закономерностей на Уоддингтонском ландшафте глиобластомы с помощью генеративно-состязательных сетей. Киберн. Сист. 2022, 53, 223–237. [\[Перекрестная ссылка\]](#)

11. Нин, Э.; Ван, К.; Чжан, Х.; Нин, Х.; Тивари, П. Повторная идентификация окклюдированного человека с помощью глубокого обучения: обзор и перспективы. Экспертная система. Прил. 2024, 239, 122419. [\[CrossRef\]](#)

12. Ли, П.; Дуан, Х. Планирование пути беспилотного летательного аппарата на основе улучшенного алгоритма гравитационного поиска. наук. Китайские технологии. 2012, 55, 2712–2719. [\[Перекрестная ссылка\]](#)

13. Цюй, К.; Гай, В.; Чжан, Дж.; Чжун, М. Новый алгоритм гибридного оптимизатора «серого волка» для планирования траектории беспилотных летательных аппаратов (БПЛА). Информационная система. 2020, 194, 105530. [\[CrossRef\]](#)

14. Дасдемир Э.; Кёксалан, М.; Озтюрк, Д.Т. Гибкий многокритериальный эволюционный алгоритм на основе контрольных точек: приложение к проблеме планирования маршрута БПЛА. Вычислитель. Опер. Рез. 2020, 114, 104811. [\[CrossRef\]](#)

15. Яо, П.; Ван, Х.; Джи, Х. Мульти-БПЛА отслеживают цель в городской среде с помощью прогнозирующего управления моделью и улучшенного оптимизатора Grey Wolf. Аэроп. наук. Технол. 2016, 55, 131–143. [\[Перекрестная ссылка\]](#)

16. Папайоанну, С.; Лаудиа, К.; Колиос, П.; Теохаридес, Т.; Панайоту, СГ. Совместная оценка и контроль для многоцелевого пассивного мониторинга с использованием автономного агента БПЛА. В материалах 31-й Средиземноморской конференции по контролю и автоматизации (MED) 2023 г., Лимассол, Кипр, 26–29 июня 2023 г.; стр. 176–181.

17. Рен, К.; Яо, Ю.; Ян, Г.; Чжоу, Х. Многоцелевое планирование траектории БПЛА в городской среде на основе CDNSGA-II. В материалах Международной конференции IEEE по сервис-ориентированной системной инженерии (SOSE) 2019 г., Сан-Франциско, Калифорния, США, 4–9 апреля 2019 г.; стр. 350–3505.

18. Прайс К.В. Введение в дифференциальную эволюцию. В «Новых идеях оптимизации»; МакГроу: Беркшир, Великобритания, 1999 г.; стр. 79–108.

19. Гад А.Г. Алгоритм оптимизации роя частиц и его приложения: систематический обзор. Арх. Вычислитель. Методы англ. 2022, 29, 2531–2561. [\[Перекрестная ссылка\]](#)

20. Ю, Х.; Цзян, Н.; Ван, Х.; Ли, М. Гибридный алгоритм, основанный на оптимизаторе «серого волка» и дифференциальной эволюции для планирования траектории БПЛА. Экспертная система. Прил. 2023, 215, 119327. [\[CrossRef\]](#)

21. Лю, Дж.; Вэй, Х.; Хуанг, Х. Улучшенный алгоритм оптимизации серого волка и его применение при планировании пути. Доступ IEEE 2021, 9, 121944–121956. [\[Перекрестная ссылка\]](#)

22. Сюэ, Дж.; Шен, Б.; Пан, А. Алгоритм усиленного поиска воробья для решения задач оптимизации. Дж. Эмбиент. Интел. Гуманиз. Вычислитель. 2023, 14, 9173–9189. [\[Перекрестная ссылка\]](#)

23. Сахингоз, О.К. Планирование летного пути для системы из нескольких БПЛА с использованием генетических алгоритмов и кривых Безье. В материалах Международной конференции по беспилотным авиационным системам (ICUAS) 2013 г., Атланта, Джорджия, США, 28–31 мая 2013 г.; стр. 41–48.

24. Кюи, З.; Чжан, Дж.; Ву, Д.; Цай, Х.; Ван, Х.; Чжан, В.; Чен, Дж. Гибридный многокритериальный алгоритм оптимизации роя частиц для проблемы добычи зеленого угля. Инф. наук. 2020, 518, 256–271. [\[Перекрестная ссылка\]](#)

25. Чжан Дж.; Сюэ, Ф.; Цай, Х.; Кюи, З.; Чанг, Ю.; Чжан, В.; Ли, В. Защита конфиденциальности на основе алгоритма многокритериальной оптимизации. Согласен. Вычислитель. Практика. Эксп. 2019, 31, e5342. [\[Перекрестная ссылка\]](#)

26. Гонг, Д.; Сан, Дж.; Мяо, З. Генетический алгоритм на основе множеств для интервальных задач многокритериальной оптимизации. IEEE Транс. Эвол. Вычислитель. 2016, 22, 47–60. [\[Перекрестная ссылка\]](#)

27. Ян, С.; Ли, М.; Лю, Х.; Чжэн, Дж. Эволюционный алгоритм на основе сетки для многокритериальной оптимизации. IEEE Транс. Эвол. Вычислитель. 2013, 17, 721–736. [\[Перекрестная ссылка\]](#)

28. Кюи, З.; Чанг, Ю.; Чжан, Дж.; Цай, Х.; Чжан, В. Улучшенный NSGA-III с оператором выбора и исключения. Рой Эвол. Вычислитель. 2019, 49, 23–33. [\[Перекрестная ссылка\]](#)

29. Хобби, Дж. Г.; Гандоми, АХ; Рахими, И. Сравнение методов обработки ограничений в NSGA-II. Арх. Вычислитель. Методы англ. 2021, 28, 3475–3490. [\[Перекрестная ссылка\]](#)

30. Лю, Ю.; Гонг, Д.; Сан, Дж.; Джин, Ю. Многокритериальный эволюционный алгоритм, использующий стратегию последовательного выбора. IEEE Транс. Киберн. 2017, 47, 2689–2702. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)

31. Гао, Х.; Чжан, Х.; Сонг, С. Эволюционный алгоритм, основанный на свойствах регулярности, для многокритериальной оптимизации. Рой Эвол. Вычислитель. 2023, 78, 101258. [\[CrossRef\]](#)

32. Бао, К.; Гао, Д.; Гу, В.; Сюй, Л.; Гудман, Э.Д. Новый адаптивный эволюционный алгоритм на основе декомпозиции для мульти-и многокритериальная оптимизация. Экспертная система. Прил. 2023, 213, 119080. [\[CrossRef\]](#)

33. Лю, С.; Лин, К.; Вонг, К.К.; Коэльо, САС; Ли, Дж.; Мин, З.; Чжан Дж. Самостоятельная стратегия опорных векторов для многоцелевых задач оптимизации. IEEE Транс. Киберн. 2020, 52, 1164–1178. [\[Перекрестная ссылка\]](#)

34. Йи, Дж.; Чжан, В.; Бай, Дж.; Чжоу, В.; Яо, Л. Многофакторный эволюционный алгоритм, основанный на улучшенной динамической декомпозиции для задач многокритериальной оптимизации. IEEE Транс. Эвол. Вычислитель. 2021, 26, 334–348. [\[Перекрестная ссылка\]](#)

35. Нонди, Дж.; Гогой, Т.К. Сравнение производительности многокритериальных эволюционных алгоритмов эскергетики и эсксргоэвнвиномики оптимизация эталонной комбинированной теплоэнергетической системы. Энергия 2021, 233, 121135. [\[CrossRef\]](#)

36. Цай, Х.; Ху, З.; Чен, Дж. Алгоритм рекомендаций по многоцелевой оптимизации, основанный на интеллектуальном анализе знаний. Инф. наук. 2020, 537, 148–161. [\[Перекрестная ссылка\]](#)

37. Цай, Т.; Ван, Х. Общий метод анализа сходимости для алгоритма эволюционной многокритериальной оптимизации. Инф. наук. 2024, 663, 120267. [\[CrossRef\]](#)

38. Дэвис, Л.; Болам, Колорадо; Вагапов Ю.; Анучин А. Обзор технологий беспилотных авиационных систем, позволяющих осуществлять операции за пределами прямой видимости (BVLOS). В материалах X Международной конференции по электроприводным системам (ICEPDS) 2018 г., Новочеркасск, Россия, 3–6 октября 2018 г.; стр. 1–6.

39. Мюллер, М.; Смит, Н.; Ганем, Б. Тест и симулятор слежения за БПЛА. В материалах Computer Vision – ECCV 2016: 14-я Европейская конференция, Амстердам, Нидерланды, 11–14 октября 2016 г.; Слушания, часть I 14; Springer: Берлин/Гейдельберг, Германия, 2016 г.; стр. 445–461.

40. Ву, Ю.; Лим, Дж.; Ян, М.Х. Отслеживание объектов в Интернете: эталон. В материалах конференции IEEE по компьютерному зрению и Распознавание образов, Портленд, Орегон, США, 23–28 июня 2013 г.; стр. 2411–2418.

41. Энрикес, Х.Ф.; Казейро, Р.; Мартинс, П.; Батиста, Дж. Высокоскоростное отслеживание с помощью корреляционных фильтров с ядром. IEEE Транс. Шаблон Анализный. Мах. Интел. 2015, 37, 583–596. [\[Перекрестная ссылка\]](#)

42. Ли, Ю.; Чжу, Дж.; Хой, Южная Каролина; Сонг, В.; Ван, З.; Лю, Х. Робастная оценка преобразования подобия для визуального отслеживания объектов. В материалах конференции AAAI по искусственному интеллекту, Гонолулу, Гавайи, США, 27 января – 1 февраля 2019 г.; Том 33, стр. 8666–8673.
43. Ван, Н.; Чжоу, В.; Тиан, К.; Хонг, Р.; Ван, М.; Ли, Х. Корреляционные фильтры с несколькими сигналами для надежного визуального отслеживания. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Солт-Лейк-Сити, Юта, США, 18–23 июня 2018 г.; стр. 4844–4853.
44. Бертинетто, Л.; Вальмадре, Дж.; Голодец С.; Миксик, О.; Торр, П.Х. Стейпл: Дополнительные учащиеся для отслеживания в реальном времени. В материалах конференции IEEE по компьютерному зрению и распознаванию образов, Лас-Вегас, Невада, США, 27–30 июня 2016 г.; стр. 1401–1409.
45. Данельян, М.; Хэгер, Г.; Хан, Ф.С.; Фельсберг, М. Космическое отслеживание дискриминационного масштаба. IEEE Транс. Паттерн Анал. Мах. Интел. 2016, 39, 1561–1575. [\[Перекрестная ссылка\]](#)
46. Ли, Ю.; Фу, К.; Дин, Ф.; Хуанг, З.; Лу, Г. AutoTrack: На пути к высокопроизводительному визуальному отслеживанию БПЛА с автоматической пространственно-временной регуляризацией. В материалах конференции IEEE/CVF по компьютерному зрению и распознаванию образов, Сиэтл, Вашингтон, США, 17–21 июня 2020 г.; стр. 11923–11932.

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.



Статья

Оптимизация размещения датчиков и методы машинного обучения для точной классификации жестов рук

Лакшья Чаплот

¹, Сара Хаушманд,¹ Карла Бельтран Мартинес ¹, Джон Андерсен 2,3 и Хосейн Рухани 1,3,*¹ Факультет машиностроения, Университет Альберты, Эдмонтон, AB T6G 2R3, Канада; lakshyachaplot@gmail.com (LC); shoushma@ualberta.ca (SH); Beltranm@ualberta.ca (KBM)² Кафедра педиатрии, Университет Альберты, Эдмонтон, AB T6G 2R3, Канада; john.andersen@albertahealthservices.ca³ Реабилитационная больница Гленроуз, Эдмонтон, AB T5G 0B7, Канада * Адрес для переписки: hrouhani@ualberta.ca

Аннотация: Миллионы людей живут с ампутациями верхних конечностей, что делает их потенциальными бенефициарами протезов кистей и предплечий. Хотя миоэлектрические протезы были разработаны для удовлетворения потребностей людей с ампутированными конечностями, проблемы по-прежнему связаны с контролем над ними. В этом исследовании используются датчики поверхностной электромиографии и методы машинного обучения для классификации пяти основных жестов рук. Используя функции, извлеченные из данных электромиографии, мы применили нелинейный машинный классификатор опорных векторов на основе многоядерного обучения для распознавания жестов. Наш набор данных включал восемь молодых участников, не имеющих инвалидности. Кроме того, в нашем исследовании был проведен сравнительный анализ пяти различных конфигураций размещения датчиков. Эти конфигурации собирают данные электромиографии, связанные с движениями указательного и большого пальцев, а также движениями указательного и безымянного пальцев. Мы также сравнили четыре разных классификатора, чтобы определить наиболее способный классифицировать жесты рук. Установка с двумя датчиками, стратегически расположенная для регистрации движений большого и указательного пальцев, была наиболее эффективной — эта установка с двумя датчиками достигла 90% точности для классификации всех пяти жестов с использованием машинного классификатора опорных векторов. Кроме того, применение многоядерного обучения в машинном классификаторе опорных векторов демонстрирует свою эффективность, достигая самой высокой точности классификации среди всех классификаторов. Это исследование продемонстрировало потенциал датчиков поверхностной электромиографии и машинного обучения в улучшении контроля и функциональности миоэлектрических протезов для людей с ампутациями верхних конечностей.

Ключевые слова: миоэлектрический датчик; жест рукой; Машина опорных векторов; протез руки; классификация; машинное обучение



Цитирование: Шаплот, Л.; Хаушманд, С.; Мартинес, КБ; Андерсен, Дж.; Рухани, Х. Оптимизация размещения датчиков и методы машинного обучения для Точная классификация жестов рук.

Электроника 2024, 13, 3072. <https://doi.org/10.3390/electronics13153072>.

Академический редактор: Янош Ботцхайм

Поступила: 7 июня 2024 г.

Пересмотрено: 24 июля 2024 г.

Принято: 1 августа 2024 г.

Опубликовано: 3 августа 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

В 2017 году глобальное число лиц с односторонней ампутацией верхних конечностей превысило 11,3 миллиона, причем еще 11,0 миллионов человек пережили двустороннюю ампутацию верхних конечностей [1]. В Канаде около 6800 человек живут с ампутацией проксимальнее запястья [2].

В недавнем исследовании [2] сравнивались результаты и затраты, связанные с двумя методами лечения ампутаций рук: васкуляризированной композитной аллотрансплантацией рук и миоэлектрическими протезами рук. Был сделан вывод, что лечение односторонних ампутаций с помощью миоэлектрических протезов было более экономически эффективным.

Миоэлектрические протезы рук стали ключевым средством восстановления как жестовых, так и хватательных способностей у людей с ампутированными конечностями, предлагая неинвазивную альтернативу постоянным хирургическим вмешательствам [2]. Преобладающие системы управления в протезах часто используют триггерный механизм, основанный на одном или двух каналах поверхностной электромиографии (ЭМГ) [3,4]. Эта установка сопоставляет события отдельных мышечных сокращений с заранее заданными последовательностями движений, что требует явных пользовательских команд для переключения режима [3,4]. Такое последовательное переключение приводит к задержке во времени выполнения, требуя нескольких отдельных команд для перехода между разными режимами захвата [3,4]. Неинтуитив-

этот процесс переключения захвата в сочетании с неудобной динамикой управления и отсутствием достаточной обратной связи был идентифицирован как основная причина низких показателей приемки, наблюдаемых для миоэлектрических протезов [5,6]. Решение этих проблем имеет важное значение для повышения удобства использования и признания миоэлектрических протезных устройств среди сообщества пользователей [5,6].

Несколько попыток классифицировать сигналы пЭМГ (поверхностной электромиографии) от мышц предплечья человека были задокументированы в предыдущих работах. Чтобы смягчить проблемы с интуитивностью, прототипы решений в существующей литературе сосредоточены на расшифровке намерений пользователя при помощи жестов, воздействуя на отдельные мышцы-сгибатели и разгибатели предплечья [7].

Произвольные сокращения оставшихся мышц предплечья после ампутации можно идентифицировать с помощью классификаторов машинного обучения, таких как искусственная нейронная сеть (ИНС), линейный дискриминантный анализ (ЛДА) и классификаторы машины опорных векторов (SVM). SVM часто выбирают из-за его математической интерпретируемости и глобальной оптимизации. Он хорошо работает даже с небольшим обучающим набором [8]. Параметр эластичности SVM, также известный как гиперпараметр ограничения коробки C, контролирует максимальный штраф, налагаемый на наблюдения, нарушающие пределы, и помогает предотвратить переобучение [8]. Палковски и Редларски [9] использовали два датчика ЭМГ на предплечье, собирая данные с частотой 16 Гц, чтобы распознать шесть жестов всей руки и запястья с помощью классификатора SVM. Ли и др. [10] успешно классифицировали десять жестов рук, используя характеристики, полученные с помощью трех датчиков ЭМГ, и достигли точности, превышающей 90% для каждого участника. Однако их модель машинного обучения прошла обучение и тестирование на наборах данных участников без объединения данных между участниками для оценки способности модели к обобщению. Такой ограничительный подход к тестированию вносит предвзятость в точность классификации, поднимая вопросы о применимости этой технологии в протезах рук. В других предыдущих работах [8,11,12] была достигнута высокая точность более 90% для классификации нескольких жестов всей руки и запястья, таких как открытие/закрытие запястья, локтевое и радиальное отклонение, а также сгибание-разгибание. Однако жесты всей руки и запястья легче классифицировать, и они имеют ограниченное функциональное применение для людей с ампутированными конечностями, стремящихся восстановить ловкость рук.

Эффективность воздействия на определенные мышцы требует стратегического размещения электродов и их конфигурации – важнейшего фактора для подходов, основанных на признаках, которые относительно неисследованы в литературе.

Этот проект был направлен на повышение точности классификации жестов рук, стратегического размещения датчиков и выбора практических жестов для потенциальной интеграции с миоэлектрическими протезами рук. Таким образом, в этом исследовании изучалась разработка классификатора SVM на основе множественного обучения ядра (MKL) для классификации пяти сложных жестов рук, имеющих решающее значение для людей с ампутированными конечностями: силового хвата (сжатия запястья), хвата крюком (четырёхзначного хвата), тонкого щипка (сжатия запястья), используя указательный и большой палец, грубое сжатие (используя все пять пальцев) и точечный жест (сгибание пальцев 3, 4 и 5). Методология исследования заключалась в создании классификатора с использованием данных, собранных с помощью пяти различных конфигураций датчиков, каждая из которых использует один или два датчика ЭМГ на предплечье, что обеспечивает минималистичный подход к сбору данных, одновременно стремясь определить оптимальное размещение датчиков для получения максимальной точности классификации.

2. Материалы и методы

2.1. Экспериментальная

процедура Данные пЭМГ были собраны на правой руке восьми участников без неврологических/скелетно-мышечных нарушений или диагноза (возраст: 21 ± 2 года (среднее $\pm$ стандартное отклонение), рост: $169,5 \pm 2,8$ см (среднее $\pm$ стандартное отклонение), масса тела : $57,9 \pm 9,5$ кг (среднее $\pm$ стандартное отклонение), 7 мужчин и 1 женщина). Все участники были ознакомлены с методикой эксперимента. Информированное согласие было получено от всех субъектов, участвовавших в исследовании. Исследование проведено в соответствии с Хельсинкской декларацией и одобрено Институциональным комитетом по этике Университета Альберты (AB T6G 2N2, одоб

Сигналы пЭМГ регистрировались с помощью биполярных датчиков MyoWare 2.0 Muscle [13]. (SparkFun Electronics, Нивот, Колорадо, США), выбранные из-за их потенциала для интеграции в недорогие протезы рук. Предыдущая версия этого датчика часто использовалась в

Сигналы пЭМГ регистрировались с помощью биполярных датчиков MyoWare 2.0 Muscle [13]. (SparkFun Electronics, Нивот, Колорадо, США), выбранные из-за их потенциала для интеграции в недорогие протезы рук. Предыдущая версия этого датчика часто использовалась в литературе из-за ее низкой стоимости, простоты настройки функций и положительных результатов в проверочных исследованиях, показавших, что она сравнима с более дорогими аналогами из-за его низкая стоимость, простые в настройке функции и высокая производительность.

коммерческие системы ЭМГ [14,15]. MyoWare 2.0 имеет три электрода: средний мышечный и конечный мышечный. По данным проверочных исследований, он сопоставим с более дорогими коммерческими электродами. [13]. Перед тем, как быть полученным микроконтроллером, дифференциальный сигнал ЭМГ-системы [14,15]. MyoWare 2.0 имеет три электрода: срединную мышцу, конечную мышцу и проходил через инструментальный усилитель с высоким CMRR (опорное подавление синфазного сигнала [13]. Перед тем, как быть полученным микроконтроллером, дифференциальный сигнал проходил коэффициент, который представляет собой отношение дифференциального усиления к синфазному усилению усилителя каскада) через инструментальный усилитель с высоким CMRR (коэффициент подавления синфазного сигнала, (140 дБ) и унитарное усиление для устранения распространенных источников шума, таких как линейный шум 50 Гц, что представляет собой отношение дифференциального усиления к синфазному усилению каскада усилителя (140 дБ). Впоследствии сигнал фильтровался полосовым фильтром первого порядка с частотой среза и унитарным коэффициентом усиления для устранения общих источников шума, таких как линейный шум частотой 50 Гц. Подразделы на частоте 20 Гц и 498 Гц [13]. После этого сигнал подвергся выпрямлению и последующей фильтрации с помощью полосового фильтра первого порядка с частотами среза на уровне сглаживания достигается с помощью схемы обнаружения огибающей нижних частот (3,6 Гц), встроенной в частоты 20 Гц и 498 Гц [13]. После этого сигнал подвергся исправлению и сглаживанию. аппаратное обеспечение датчика, что приводит к линейной огибающей сигнала ЭМГ. Огибающая ЭМГ, полученная с помощью низкочастотной схемы обнаружения огибающей (3,6 Гц), встроенной в аппаратный выход датчика, затем была получена микроконтроллером (Arduino UNO) с помощью программного обеспечения для выборки, в результате чего получилась линейная огибающая сигнала ЭМГ. Конвертированный выходной сигнал ЭМГ был частота 780 Гц (SD = 5 Гц) для решения проблем, связанных с недостаточной дискретизацией предыдущих данных, а затем полученной микроконтроллером (Arduino UNO) с частотой дискретизации 780 Гц.

исследования [16]. (SD = 5 Гц), чтобы решить проблемы, связанные с недостаточной выборкой в предыдущих исследованиях [16]. Конфигурации размещения датчика ЭМГ были основаны на жестах, которые должны были быть Конфигурации размещения датчика ЭМГ были основаны на жестах, которые должны были быть классифицированы. Датчики были размещены только вдоль тех мышц предплечья, которые наиболее ответственны за классификацию. Датчики были размещены только вдоль тех мышц предплечья, которые в основном ответственны за для сгибания указательного, безымянного и большого пальцев. Использовались пять жестов: (1) а для сгибания указательного, безымянного и большого пальцев. Пять использованных жестов были (1) грубое щипание, используя все пять пальцев, (2) тонкое щипание, используя указательный и большой пальцы, (3) крючок, грубое щипание, используя все пять пальцев, (2) тонкое щипание, используя указательный и большой пальцы, (3) крючок, захват (четырёхзначный захват), (4) точечный жест (сгибание цифр 3, 4 и 5) и (5) силовой захват (четырёхзначный захват), (4) точечный жест (сгибание цифр 3, 4 и 5) и (5) силовой захват (четырёхзначный захват), хват (сжатие запястья), обозначенный по классификатору от 0 до 4 соответственно. Эти пять (сжатие запястья) обозначены в классификаторе от 0 до 4 соответственно. Эти пять (сжатие запястья) обозначены жесты (рис. 1) считаются очень полезными для людей с ампутированными конечностями в их повседневной жизни, а (рис. 1) считаются очень полезными для людей с ампутированными конечностями в их повседневной жизни, а также наблюдаются в коммерческом протезировании [3,4]. также наблюдаются в коммерческом протезировании [3,4].


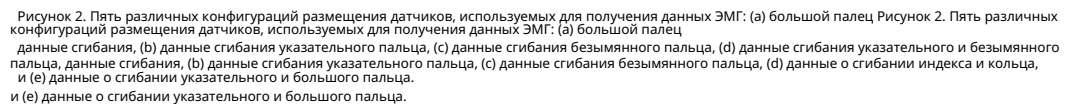


Рисунок 1. Пять различных жестов соответствуют указанным макетам протезов: (а) грубое щипание; (в) тонкое щипание; (с) захват крюком; (d) точечный жест; (e) силовой захват.

Датчики ЭМГ были размещены в трех местах на вентральной стороне предплечья (рис. 2) в пяти различных конфигурациях для получения сигналов ЭМГ от мышц, в первую очередь ответственных за сгибание указательного, безымянного и большого пальцев. Датчик отвечает за сгибание указательного, безымянного и большого пальцев. Конфигурации датчиков основаны на [17–19] и описываются следующим образом:

- C1: Один датчик расположен проксимальнее запястья вдоль длинного сгибателя большого пальца руки для получения данных о сгибании большого пальца.
- C2: Один датчик расположен проксимальнее запястья вдоль поверхностного сгибателя пальцев, чтобы получить данные о сгибании указательного пальца.
- C3: Один датчик расположен вдоль поверхностного сгибателя пальцев и поверхностного сгибателя пальцев. profundus для получения данных о сгибании безымянного пальца.
- C4: Два датчика расположены проксимальнее запястья вдоль поверхностного сгибателя пальцев, чтобы получить данные о сгибании указательного пальца и проксимальнее локтя вдоль сгибателя пальцев. superficialis и глубокий сгибатель пальцев для получения данных о сгибании безымянного пальца.

- Участник жест повторял указанный жест 20 раз с указанием времени. Участников попросили повторить дважды две секунды между жестами. После выполнения одного раунда для одного раунда данные кол- интервал в две секунды между жестами, а также 4 минуты на отдых, чтобы расслабить мышцы перед сбором для одного жеста, участник не видел перед собой монитор своего раунда, чтобы избежать жести. Измеряемые сигналы предотвращают искажения ЭМГ, регистрировались одновременно, от двух датчиков ЭМГ.



Устранение шума в сигналах ЭМГ имеет решающее значение для повышения точности классификации. Использование эффективной техники фильтрации существенно способствует улучшению качества сигнала ЭМГ. Для уточнения сигналов ЭМГ, полученных для конкретных жестов каждого участника, был применен процесс цифровой фильтрации. Этот процесс был направлен на устранение неустойчивых пиков и локальные экстремумы помех от сигналов ЭМГ с длинной огибающей, как видно на рисунке 4. Среди различных методов фильтрации рекомендуется использовать сглаживающий фильтр Гаусса (GSP). в [20] оказался многообещающим подходом, ведущим к улучшению моделирования сигналов ЭМГ и точность (рис. 4). Чтобы облегчить анализ на основе извлечения признаков, длинные данные ЭМГ последовательность действий каждого участника для одного жеста была разбита на меньшие окна, каждое из которых содержит четыре жеста для конкретного участника. Отдельные последовательности примерно

Длина 8000 выборок хранилась отдельно для последующей временной и частотной области. извлечение признаков.

Рисунок 3. Блок-схема обработки данных ЭМГ.




Рисунок 3. Блок-схема обработки данных ЭМГ.

Рисунок 3. Блок-схема обработки данных ЭМГ.




Рисунок 4. Отфильтрованный сигнал ЭМГ для жеста захвата силы (пример показан для конфигурации С3 и жеста захвата).

2.3. Извлечение и выбор признаков.

Извлечение признаков имеет решающее значение для уменьшения размерности данных, представляющих собой жест, что позволяет классифицировать жесты. Всего из 8000 выборок длинносегментированных сигналов ЭМГ было выделено 22 характеристики во временной и частотной области. Характеристики домена были извлечены из 8000 выборок длинных сегментированных сигналов ЭМГ для каждого жеста. Функции включали статистические показатели, такие как среднееквадратическое значение (RMS), дисперсия (VAR), среднее абсолютное значение (MAV), изменение знака наклона (SSC), пересечение нуля (ZC), (ZC), длина сигнала (WL), медианное абсолютное отклонение (MAD), асимметрия, эксцесс и энергия. Эти особенности хорошо известны в литературе благодаря их полезности в жестах. Эти функции хорошо известны в литературе благодаря их полезности для распознавания жестов [21,22]. Функции частотно-временной области включают модель авторегрессии. Характеристики частотно-временной области включают коэффициенты авторегрессионной модели (5-го порядка), энтропию (на основе приближительных коэффициентов одномерного дискретного вейвлета).

преобразование уровня 4), оценки дисперсии (на основе максимального перекрытия дискретного вейвлета

преобразование уровня 3), спектральная энтропия, средняя частота и мощность полосы. Вейвлет Рисунок 4. Отфильтрованный сигнал ЭМГ для жеста захвата силы (пример показан для конфигурации С3, а преобразования были основаны на вейвлете Добеши-2). Выявлены и использованы выделенные функции. жест захвата власти).

несколько раз в литературе [10,23,24]. Для облегчения эффективной классификации извлеченные признаки были нормализованы до нулевого среднего значения путем вычитания среднего значения из каждой выборки. 2.3: Извлечение и выбор признаков и их нормализация с использованием стандартного отклонения.

Извлечение признаков имеет решающее значение для уменьшения размерности данных, представляющих анализ главных компонент (PCA), который использовался на этапе выбора признаков в качестве ключевого фактора. жест, что позволяет классифицировать жесты. Всего 22 шага по времени и частоте для дальнейшего уменьшения размерности пространства признаков, полученного на основе

Характеристики домена были извлечены из 8000 выборок длинных сегментированных сигналов ЭМГ для сегментированных данных ЭМГ, полученных двумя датчиками. С первоначальным набором функций, включающим каждый из 22 функций (как), среди которых были такие, как среднееквадратическое значение (RMS), 44 различных функций.

дисперсия (VAR), среднее абсолютное значение (MAV), изменение знака наклона (SSC), переход через ноль (ZC), новый набор главных компонент, основанные на PCA, извлечены, чтобы сохранить наиболее информативную информацию. длина сигнала (WL), медианное абсолютное отклонение (MAD), асимметрия, эксцесс и компоненты при уменьшении эргия. Эти функции хорошо известны в литературе благодаря их полезности для распознавания жестов [21,22]. Функции частотно-временной области включают модель авторегрессии.

по всему набору данных были тщательно отобраны. Этот критерий отбора обеспечивал сохранение только тех компонентов, которые существенно влияли на дисперсию данных, тем самым сжимая пространство признаков, сохраняя при этом важную информацию. Эти выбранные компоненты, которые отражали большую часть изменчивости набора данных, затем были загружены исключительно в классификатор. Такое стратегическое использование сокращенных, но информативных функций, полученных из PCA, было направлено на повышение эффективности классификации за счет сосредоточения внимания на наиболее важных аспектах данных ЭМГ.

2.4. Классификатор машинного обучения

В этой статье SVM использовался для классификации пяти жестов рук. Поскольку SVM — это метод, основанный на ядре, выбор правильных функций ядра и связанных с ними гиперпараметров является важной задачей. Эту проблему обычно решают методом проб и ошибок. Более того, типичное одноядерное приложение SVM часто использует одни и те же гиперпараметры для каждого класса, и оно может оказаться непригодным, когда распределение шаблонов функций значительно различается между разными классами. Хотя существуют разные ядра, такие как ядро Гаусса, полиномиальное ядро и сигмовидное ядро, часто неясно, какое ядро является наиболее подходящим для данного набора данных, и поэтому желательно, чтобы методы ядра использовали оптимизированную функцию ядра, которая хорошо адаптируется к имеющемуся набору данных и типу границ между классами. Эффективный способ спроектировать ядро, оптимальное для данного набора данных, — это рассматривать ядро как выпуклую комбинацию базисных ядер, как показано в уравнении (1).

Такая SVM на основе MKL вдохновлена [25].

$$K(x, y) = a \cdot K_1(x, y) + b \cdot K_2(x, y) + c \cdot K_3(x, y) + d \cdot KRBF(x, y) \quad (1)$$

Здесь K_1 — линейное ядро, K_2 — квадратичное ядро, K_3 — кубическое ядро, а $KRBF$ — ядро гауссовой или радиальной базисной функции со стандартным отклонением, равным единице. Коэффициенты $\{a, b, c, d\}$ представляют собой гиперпараметры, которые необходимо настроить с использованием перекрестной проверки 10-кратного поиска по сетке. Параметр эластичности или ограничение C также является гиперпараметром, выражающим степень ослабления ограничения. Большой C может более правильно классифицировать обучающие выборки, но в конечном итоге приводит к переобучению и снижению точности тестирования, поэтому ограничение блока также настраивается с использованием перекрестной проверки 10-кратного поиска по сетке. Обучение и тестирование данных выполняются с использованием типичного разделения поездов: тестирование 80–20. PCA использовался для выбора признаков, чтобы еще больше уменьшить размерность входного вектора, передаваемого классификатору, и выбирать только статистически значимые признаки.

Дальнейший анализ включал использование трех классификаторов машинного обучения: наивного Байеса, дерева решений и KNN. Это было предпринято для оценки производительности SVM в конкретном наборе данных и экспериментальных условиях с упором на надежность при увеличении количества жестов и различных конфигурациях датчиков. Хотя SVM хорошо зарекомендовали себя как эффективные для распознавания жестов на основе ЭМГ [26,27], исследование направлено на изучение этих результатов в рамках нашей уникальной установки, в которой используются коммерчески доступные недорогие датчики sEMG. Подтвердив надежность и эффективность SVM в этом приложении, к существующей теории будут добавлены дополнительные доказательства с учетом любых нюансов из нашего конкретного набора данных.

3. Результаты

3.1. Оценка конфигурации датчика Лучший

набор гиперпараметров, обеспечивающий наивысшую точность данных тестирования для SVM, наивного Байеса, KNN и классификаторов дерева решений, построенных с использованием объединенного набора данных всех участников в различных конфигурациях датчиков, показан в Таблице 1, Таблица 2, таблица 3 и таблица 4 соответственно. Соответствующие гиперпараметры настраиваются с использованием перекрестной проверки 10-кратного поиска по сетке, а метки, используемые для каждого жеста, приведены на рисунке 1.

Таблица 1. Оптимальная конфигурация гиперпараметров для классификации жестов на основе SVM с использованием 10-кратного перекрестная проверка. Порядок ядра SVM — это порядок чистого полиномиального ядра. {a, b, c, d} — MKL коэффициенты. C — ограничение коробки. C1 , C2 , C3 , C4 , C5 — пять различных конфигураций датчиков.

Гиперпараметры		Конфигурации датчиков				
		C1	C2	C3	C4	C5
Классификация пяти жестов, включая грубый щипок, тонкий щипок, захват крючком, точечный жест и силовой захват	Порядок ядра SVM	3	-	-	-	-
	Коэффициенты MKL	a	10	0,1	0,1	1
		b	0,5	1	1	0,001
		c	0,1	10	10	0
		d	0	0	0	0
	C (ограничение поля)	1	0,1	0,5	0,5	1
Классификация двух жестов, включая тонкий щипок и силовой захват	Порядок ядра SVM	1	3	1	2	3
	Коэффициенты MKL	a	-	-	-	-
		b	-	-	-	-
		c	-	-	-	-
		d	-	-	-	-
	C (ограничение поля)	10	1	0,5	0,02	1

Таблица 2. Оптимальная конфигурация гиперпараметров для наивной классификации жестов на основе Байеса с использованием 10-кратная перекрестная проверка. Ядро распределения «N» — это нормальное ядро, а «B» — коробочное (однородное) ядро.

Гиперпараметры		Конфигурации датчиков				
		C1	C2	C3	C4	C5
Классификация пяти жестов, включая грубый щипок, тонкий щипок, захват крючком, точечный жест и силовой захват	Ядро дистрибутива (Н/Б)	Н	Б	Н	Н	Н
	Пропускная способность	0,05	0,8	0,08	0,15	0,42
Классификация двух жестов, включая тонкий щипок и силовой захват	Ядро дистрибутива (Н/Б)	Н	Н	Н	Н	Н
	Пропускная способность	0,1	0,05	0,1	0,05	0,05

Таблица 3. Оптимальная конфигурация гиперпараметров для классификации жестов на основе KNN с использованием 10-кратного перекрестная проверка. D1 – D4 обозначают евклидову функцию, косинус, городской квартал и функцию расстояния Минковского.

Гиперпараметры		Конфигурации датчиков				
		C1	C2	C3	C4	C5
Классификация пяти жестов, включая грубый щипок, тонкий щипок, захват крючком, точечный жест и силовой захват	Функция расстояния	D1	D2	D1	D1	D1
	значение K	1	1	1	1	2
Классификация двух жестов, включая тонкий щипок и силовой захват	Функция расстояния	D1	D3	D2	D1	D4
	значение K	1	1	1	1	1

Таблица 4. Оптимальная конфигурация гиперпараметров для классификации жестов на основе дерева решений с использованием 10-кратной перекрестной проверки.

Гиперпараметры		Конфигурации датчиков				
		C1	C2	C3	C4	C5
Классификация пяти жестов, включая грубый щипок, тонкий щипок, захват крючком, точечный жест и силовой захват	Минимальный размер листа	1	9	2	2	2
Классификация двух жестов, включая тонкий щипок и силовой захват	Минимальный размер листа	2	9	9	2	2

В таблице 5 представлены результаты производительности различных классификаторов на двух отдельных жестях. задач классификации с различными конфигурациями (C1, C2, C3, C4, C5) и предоставляет сравнительный обзор точности различных классификаторов по пяти различным и несвязанным между собой задачам. конфигурации датчиков для задач классификации жестов. Классифицируя пять жестов, SVM Производительность классификатора колеблется от 75% до 90%, при этом наибольшая точность наблюдается у конфигурация C5. Точность KNN колеблется, достигая максимального значения в 82% при C4 и немного ниже на уровне 80% с C5. Наивный Байес показывает свой лучший результат в 70% с C5, в то время как Ограничение классификатора дерева решений составляет 75% при той же конфигурации.

Таблица 5. Точность тестирования SVM, KNN, наивного Байеса и классификаторов дерева решений по различные конфигурации датчиков. C1 – C5 — это пять различных конфигураций датчиков.

Классификатор		Конфигурация Ci				
		C1	C2	C3	C4	C5
Классификация пяти жестов, включая грубый щипок, тонкий щипок, захват крючком, точечный жест и силовой захват	СВМ	75%	75%	84,6%	87,2%	90%
	КНН	67,9%	73,9%	69,2%	82%	80%
	Наивный Байес	53,6%	51,3%	61,5%	61,5%	70%
	Древо решений	57,2%	59%	56,4%	59%	75%
Классификация двух жестов, включая тонкий щипок и силовой захват	СВМ	100%	100%	100%	100%	100%
	КНН	100%	86,7%	100%	93,3%	100%
	Наивный Байес	100%	73,3%	100%	93,3%	93,3%
	Древо решений	100%	86,7%	100%	80%	100%

Напротив, задача классификации двух жестов, тонкого щипка и мощного хвата, демонстрирует заметно более высокую и идеальную производительность классификатора SVM, сохраняя 100% точность. во всех конфигурациях. Классификаторы KNN и дерева решений также работают исключительно хорошо. ну, при этом KNN достигает 100% точности во всех случаях, кроме C2 и C4, где он немного набирает очки ниже – 86,7% и 93,3% соответственно. Наивный Байес и классификаторы дерева решений демонстрируют идеальную 100% точность для конфигурации C3. Эта явная разница в производительности между задачами предполагает, что некоторые классификаторы, особенно SVM, могут быть более устойчивыми к изменения в конфигурации или лучше подходят для задач двоичной классификации в контексте распознавание жестов.

3.2. Оценка классификатора

Матрица путаницы для классификатора SVM в различных конфигурациях была тщательно прорисовано, чтобы обеспечить полную визуализацию производительности модели (рисунок 5).




Рисунок 5. Матрица ошибок для классификатора SVM в различных конфигурациях.

4. Дискуссия

Исследование выходит за рамки оценки точности классификации, углубляясь в комплексный анализ эффективности обработки сигналов. Результаты подтверждают эффективность предложенных исследований. Это исследование не только выявляет оптимальные конфигурации, но и предоставляет ценные данные для будущих исследований. Мы оценили эффективность различных классификаторов машинного обучения: SVM, наивный Байес, KNN и деци-дерево. Кроме того, мы исследовали различные конфигурации датчиков для сбора подробной ЭМГ-информации с предплечий восьми участников. Обширный набор из 22 функций, включающий как временная, так и частотная области для каждого датчика были извлечены из сигналов ЭМГ. Прежний исследования показывают, что набор функций смешанного домена может повысить производительность классификатора [29].

Применение PCA для выбора ключевых признаков значительно уменьшило размерность пространства признаков, повысив точность классификации. Результаты, обобщенные в таблицах 1–5, определили установку датчиков C5 (два датчика, расположенные проксимальнее запястья вдоль поверхностного сгибателя пальцев и длинного сгибателя большого пальца) как наиболее эффективную, обеспечивающую высочайшую точность с помощью SVM, наивного Байеса и дерева решений. Классификатор SVM, созданный на базе MKL, постоянно достигал точности более 90 % при классификации жестов с помощью C5, как показано в Таблице 2 и Рисунке 5. Конфигурация C5 с двумя датчиками, которая собирает данные от мышц, контролирующих движения большого и указательного пальцев, предлагает выгодную стратегию размещения датчиков при проектировании протезов рук.

Жест с тонким щипком, изображенный на рисунке 1b, оказался особенно сложным из-за более низкого уровня сокращения мышц и использования всего двух пальцев, что делало его более склонным к шуму. Точное расположение датчика C5 над активными мышцами во время этого жеста позволило получить более детальные данные. Сравнение C1 и C5 (рис. 2) иллюстрирует значительное влияние дополнительного датчика ЭМГ на точность классификации, подтверждая превосходство двухканальной ЭМГ над одноканальной в распознавании жестов.

Когда ограниченное пространство ограничивает размещение датчика возле запястья на протезной руке, C4 (два датчика, расположенные проксимальнее запястья вдоль поверхностного сгибателя пальцев, вдоль поверхностного сгибателя пальцев и глубокого сгибателя пальцев) становится возможной альтернативой, достигая точности 87,2% с помощью SVM (Таблица 5). Эти результаты подчеркивают важность как расположения датчика на мышце, так и близости к брюшку мышцы для оптимального сбора данных.

Улучшение характеристик SVM с помощью MKL очевидно в конфигурации датчика C3 (один датчик расположен вдоль поверхностного сгибателя пальцев и глубокого сгибателя пальцев), где одиночный датчик близко конкурирует с двойным датчиком C4 по точности (точность тестирования SVM, таблица 5). Адаптивный выбор функций ядра MKL для данных C3 является значительным шагом вперед по сравнению с одноядерными методами. Гиперпараметр C SVM играет ключевую роль в балансировании сложности модели и переобучения, его диапазон значений от 0,01 до 10 оценивается посредством перекрестной проверки 10-кратного поиска по сетке (таблица 1). Эта тонкая настройка имела решающее значение для разработки оптимизированной модели SVM с сильными возможностями обобщения для точной классификации жестов. Таким образом, для протезов рук, которые могут включать только один датчик ЭМГ, рекомендуемой настройкой является C3. Использование MKL с SVM значительно повышает производительность по сравнению с базовыми SVM, особенно при классификации нескольких жестов, и позволило нам добиться ненулевых коэффициентов MKL для классификации всех пяти жестов, как подробно описано в таблице 1. Хотя базовые SVM превосходны в двоичной классификации, MKL обрабатывает сложность сигналов ЭМГ улучшается за счет объединения нескольких ядер. Это приводит к надежной классификации пяти различных жестов, что оправдывает дополнительную сложность MKL.

Матрицы путаницы демонстрируют высокую производительность SVM по различным жестам — от 80% до 100% в конфигурации C5. Кроме того, SVM преуспел в качестве двоичного классификатора жестов мелкого щипка и силового хвата (рис. 1), достигнув 100% точности. Отмеченной тенденцией является снижение точности классификации с увеличением количества жестов, явление, которое перекликается с предыдущими результатами [26]. Это снижение объясняется более широкой дисперсией сигналов ЭМГ в предплечье и результирующим перекрытием сигналов от одновременных сокращений мышц при выполнении сложных жестов.

Потенциальным ограничением настоящего исследования, если его расширить до онлайн-классификации ЭМГ в реальном времени, является небольшое изменение длины сегментов ЭМГ во временной области, используемых для извлечения признаков в различных конфигурациях жестов. Это ограничение можно легко устранить, выбрав точно равные длины сегментов во время онлайн-заявки. Еще одним ограничением текущей работы является размер выборки в восемь участников. Этот размер выборки аналогичен другим размерам выборок в литературе [25,27]. Однако ограниченный размер выборки может повлиять на надежность точности, полученной до определенного уровня. Настоящее исследование служит для проверки предложенной методологии в небольшом масштабе, и в будущем планируется провести эксперименты с большим размером выборки и включить людей с различиями в конечностях, чтобы напрямую оценить применение наших результатов в управлении протезами рук. Это повысит обобщаемость и актуальность текущего исследования.

Будущие исследования будут применять результаты этой статьи для воспроизведения жестов рук в миоэлектрическом протезе руки в режиме реального времени. Также будут изучены различные конфигурации датчиков и методы машинного обучения для дальнейшего повышения эффективности миоэлектрических протезов. Кроме того, разработка более сложных методов извлечения признаков и оптимизации классификаторов может быть полезна при многогранном анализе сигналов ЭМГ. Это исследование послужит ступенькой на пути к созданию более эффективных и действенных миоэлектрических протезов, и есть надежда, что полученные знания вдохновят на дальнейшие исследования в этой многообещающей области.

5. Выводы

Это исследование позволило добиться значительных успехов в области технологии миоэлектрического протезирования и получить ключевые результаты, которые могут повлиять на будущие исследования и применения. Превосходные характеристики двухканальной конфигурации указательного кольца и указательного большого пальца (C4 и C5) подчеркивают важность оптимального размещения датчика для повышения функциональности миоэлектрических протезов. Применение MKL в классификаторе SVM, в частности при размещении одного датчика в кольце (конфигурация C3), продемонстрировало свою эффективность в достижении высокой точности классификации даже с одним датчиком. Наблюдаемое снижение точности с увеличением количества жестов подчеркивает необходимость комплексного извлечения признаков и оптимизации классификатора для сложного анализа сигналов ЭМГ. Эти результаты в совокупности открывают путь к прогрессу в области миоэлектрических протезов, подчеркивая необходимость в усовершенствованных конфигурациях датчиков и методологиях машинного обучения для повышения точности распознавания жестов.

Вклад авторов: концептуализация, LC, SH, KBM, JA и HR; Методология, LC, SH, KBM, JA и HR; Программное обеспечение, LC и SH; Валидация, LC, SH, KBM и HR; Формальный анализ, LC, SH, JA и HR; Расследование, LC, SH, KBM, JA и HR; Ресурсы, KBM, JA и HR; Курирование данных, LC, SH, KBM и HR; Письмо — первоначальный проект, LC, SH, KBM, JA и HR; Написание — рецензирование и редактирование, LC, SH, KBM, JA и HR. Все авторы прочитали опубликованную версию рукописи и согласились с ней.

Финансирование: Данное исследование финансировалось Фондом больницы Гленроуз и компанией Mitacs, номер гранта: IT36690.

Заявление Институционального наблюдательного совета: Исследование было проведено в соответствии с Хельсинкской декларацией и одобрено Институциональным комитетом по этике Университета Альберты (AB T6G 2N2, одобрено 25 апреля 2022 г.).

Заявление об информированном согласии: все участники подписали форму согласия, процедура была одобрена Советом по этике исследований Университета Альберты, номер заявки: Pro00117863.

Заявление о доступности данных: данные доступны по запросу.

Конфликты интересов: Авторы заявляют об отсутствии конфликта интересов.

Рекомендации

1. Макдональд, CL; Уэсткотт-Маккой, С.; Уивер, MR; Хаагсма, Дж.; Картин, Д. Глобальная распространенность травм несмертельных конечностей ампутация. Протез. Ортоп. Межд. 2021, 45, 105–114. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)
2. Ефанов Ю.; Чилоэмба, Б.; Изадпанах, А.; Харрис, П.; Данино, М. Обзор полезностей и затрат на лечение ампутаций верхних конечностей с помощью васкуляризированной композитной аллотрансплантации по сравнению с миоэлектрическими протезами в Канаде. JPRAS Open 2022, 32, 150–160. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)
3. Руководство пользователя Hero Arm — Open Bionics. Доступно онлайн: <https://openbionics.com/hero-arm-user-guide/>. (доступ 9 декабрь 2023 г.).
4. bebionic|Оттобок США. Доступно онлайн: <https://www.ottobockus.com/prosthetics/upper-limb-prosthetics/solution-overview/бебионическая рука/> (по состоянию на 9 декабря 2023 г.).
5. Пердеман, Б.; Боэр, Д.; Виттевен, Х.; Херменс, Х.; Страмиджиоли, С.; Ритман, Х.; Вельтинк, П.; Мисра, С. Миоэлектрические протезы предплечья: современное состояние с точки зрения пользователя. Дж. Реабилит. Рез. Дев. 2011, 48, 719–738. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)
6. Корделла, Ф.; Чианчио, Алабама; Саккетти, Р.; Давалли, А.; Катти, АГ; Гульельмелли, Э.; Золло, Л. Обзор литературы о потребностях верхних Пользователи протезов конечностей. Передний. Неврология. 2016, 10, 209. [\[CrossRef\]](#) [\[ПабМед\]](#)
7. Гитанджали, П. Миоэлектрический контроль протезов рук: современный обзор. Мед. Приборы 2016, 9, 247–255. [\[Перекрестная ссылка\]](#) [\[ПабМед\]](#)

8. Таваколи, М.; Бенусси, К.; Лопес, Пенсильвания; Осорио, ЛВ; де Алмейда, Австралия Надежное распознавание жестов рук с помощью двухканального носимого браслета EMG с поверхностью и классификатора SVM. Биомед. Сигнальный процесс. Контроль. 2018, 46, 121–130. [\[Перекрестная ссылка\]](#)
9. Палковский А.; Редларски, Г. Основная классификация жестов рук на основе поверхностной электромиографии. Вычислить. Математика. Методы Мед. 2016, 2016, 6481282. [\[CrossRef\]](#) [\[PubMed\]](#)
10. Ли, К.Х.; Мин, Ю; Бьюн, С. Классификация жестов рук и пальцев на основе электромиограммы с использованием искусственных нейронных сетей. Датчики 2021, 22, 225. [\[CrossRef\]](#) [\[PubMed\]](#)
11. Махсан Р.; Ибрагими, Мичиган; Халифа О.О. Распознавание жестов рук на основе сигналов электромиографии (ЭМГ) с использованием искусственной нейронной сети (ИНС). В материалах 4-й Международной конференции по мехатронике 2011 г.: Интегрированная инженерия для промышленного и социального развития, ICOM'11 — Материалы конференции, Куала-Лумпур, Малайзия, 17–19 мая 2011 г. [\[CrossRef\]](#)
12. Киса, Д.Х.; Оздемир, Массачусетс; Гурен, О.; Акан, А. Классификация жестов рук на основе ЭМГ с использованием временных рядов разложения эмпирического режима и глубокого обучения. В материалах Конгресса медицинских технологий TIRTEKNO 2020 — Tıp Teknolojileri Kongresi — 2020, TIRTEKNO 2020, Анталья, Турция, 19–20 ноября 2020 г. [\[CrossRef\]](#)
13. Датчик мышц MYOWARE® 2.0. Доступно онлайн: <https://myoware.com/products/muscle-sensor/>. (по состоянию на 9 декабря 2023 г.). 14. дель Торо, Сан-Франциско; Вэй, Ю.; Ольмеда, Э.; Рен, Л.; Гуоу, В.; Диас, В. Валидация недорогой системы электромиографии (ЭМГ) с помощью Коммерческое и точное устройство ЭМГ: пилотное исследование. Датчики 2019, 19, 5214. [\[CrossRef\]](#) [\[PubMed\]](#)
15. Хейвуд, С.; Пуа, Ю.Х.; Макклелланд, Дж.; Гейгл, П.; Рахманн, А.; Бауэр, К.; Кларк, Р. Недорогая электромиография – проверка на соответствие коммерческой системе с использованием как ручных, так и автоматических пороговых значений времени активации. Дж. Электромиогр. Кинезиол. 2018, 42, 74–80. [\[Перекрестная ссылка\]](#) [\[PubMed\]](#)
16. Курниаван, СР; Памунгас, Д. МЙО. Датчики наручных повязок и алгоритм нейронной сети для управления ручным роботом. В материалах Международной конференции по прикладной инженерии 2018 г., ICAE 2018, Батам, Индонезия, 3–4 октября 2018 г. [\[Перекрестная ссылка\]](#)
17. Мао, З.-Х.; Ли, Х.-Н.; Склабасси, Р.Дж.; Сунь М. Информационная емкость большого и указательного пальцев при общении. IEEE Транс. Биомед. англ. 2009, 56, 1535–1545. [\[Перекрестная ссылка\]](#) [\[PubMed\]](#)
18. Хиоки, М.; Кавасаки, Х. Оценка углов суставов пальцев по sEMG с использованием нейронной сети, включая коэффициент временной задержки и Рекуррентная структура. ISRN Реабилитация. 2012, 2012, 604314. [\[CrossRef\]](#)
19. Эксперимент: Классификация сигналов. Доступно онлайн: <https://backyardbrains.com/experiments/RobotHand>. (доступ 9 декабря 2023 г.).
20. Галян, IFJ; Абуэленин З.М.; Аннамалай, Г.; Капила, В. Гауссов сглаживающий фильтр для улучшения моделирования сигналов ЭМГ. В области обработки сигналов в медицине и биологии: новые тенденции в исследованиях и приложениях; Шпрингер: Чам, Швейцария, 2020 г.; стр. 161–204. [\[Перекрестная ссылка\]](#)
21. Харамильо-Янес, А.; Беналякасар, Мэн; Мена-Мальдонадо, Э. Распознавание жестов рук в реальном времени с использованием поверхностной электромиографии и машинного обучения: систематический обзор литературы. Датчики 2020, 20, 2467. [\[CrossRef\]](#) [\[PubMed\]](#)
22. Ткач Д.; Хуанг, Х.; Куикен, Т.А. Исследование стабильности характеристик во временной области для распознавания электромиографических образов. Дж. Нойроенг. Реабилитация. 2010, 7, 21. [\[CrossRef\]](#) [\[PubMed\]](#)
23. Хайруддин И.М.; Сидек, С.Н.; Маджид, АРРА; Разман, МАМ; Пузи, А.А.; Юсоф, Х.М. Классификация намерения движения с помощью моделей машинного обучения: выявление существенных особенностей ЭМГ во временной области. ПирДж Компьютер. наук. 2021, 7, e379. [\[Перекрестная ссылка\]](#) [\[PubMed\]](#)
24. Томашевский Дж.; Амарал, Т.; Диас, О.; Волчковский, А.; Куржинский, М. Классификация сигналов ЭМГ с использованием нейронной сети с AR коэффициенты модели. Учебник МФБ. Том. 2009, 42, 318–325. [\[Перекрестная ссылка\]](#)
25. Она, К.; Луо, З.; Мэн, М.; Сюй, П. Классификация моделей ЭМГ на основе множественного ядра обучения на основе SVM для контроля нижних конечностей. В материалах 11-й Международной конференции по управлению, автоматизации, робототехнике и зрению, ICARCV 2010, Сингапур, 7–10 декабря 2010 г.; стр. 2109–2113. [\[Перекрестная ссылка\]](#)
26. Одеями Дж.; Огбейеми, А.; Вонг, К.; Чжан В. Об автоматическом захвате объектов интеллектуальными протезами рук с использованием машинного обучения. Биоинженерия 2024, 11, 108. [\[CrossRef\]](#) [\[PubMed\]](#)
27. Авилес, М.; Санчес-Рейес, Л.-М.; Фуэнтес-Агилар, RQ; Толедо-Перес, округ Колумбия; Родригес-Ресендис, Дж. Новая методология классификации движений ЭМГ на основе SVM и генетических алгоритмов. Микромашины 2022, 13, 2108. [\[CrossRef\]](#) [\[PubMed\]](#)
28. Фахардо, Ж.М.; Гомес, О.; Прието, Ф. Классификация жестов рук ЭМГ с использованием ручных и глубоких функций. Биомед. Сигнальный процесс. Контроль. 2021, 63, 102210. [\[CrossRef\]](#)
29. Аббаспур, С.; Линден, М.; Голамхоссейни, Х.; Набер, А.; Ортис-Каталан, М. Оценка алгоритмов распознавания на основе поверхностной ЭМГ для декодирования движений рук. Мед. Биол. англ. Вычислить. 2020, 58, 83–100. [\[Перекрестная ссылка\]](#) [\[PubMed\]](#)

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно отдельному автору(ам) и участникам(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.



Статья

Улучшение полезности данных при сохранении конфиденциальности данных о местоположении
Сбор с помощью адаптивного разделения по сетке

Чонвук Ким



Факультет компьютерных наук, Университет Санмён-сеул 03016, Республика Корея ; jkim@smu.ac.kr

Аннотация: Широкая доступность устройств с поддержкой GPS и достижения в областитехнологийпозиционированиязначительнооблегчилисборданныхоместоположениипользователей,чтосделалоихбесценнымактивомдляразличныхотраслей. Врезультатерастетспроснасбориобменэтими данными. Учитываяконфиденциальныяхарактеринформацииоместоположениипользователя,былипредпринятызначительныеусилиядляобеспеченияконфиденциальности,приэтомсхемы,основанныенадифференциальнойконфиденциальностью(DP),сталинаиболеепредпочтительнымподходом.Однакоэтими методамиобычнопредставляютсяместоположенияпользователейравномерноразделенныхсетях,которыечастонеточноотражаютистинноераспределениепользователейвпространстве.Поэтомувэтойстатье мыпредставляемновыйметод,которыйадаптивнонастраиваетсеткуврежиме реальноговременивовремясбораданных,темсамымпредставляяпользователейвэтихдинамическиразделенныхсетях,чтобыповыситьполезностьсобранныхданных. Вчастности,нашметоднапрямуюфиксируетраспределениепользователейвовремяпроцессасбораданных,устраняянеобходимостьполагатьсянауже существующие данные ораспределениипользователей. Результатыэкспериментовсреальныминаборамиданныхпоказывают,чтопредложеннаясхемазначительноповышаетполезностьсобранныхданныхоместоположениипосравнениюс существующимметодом.

Ключевые слова: конфиденциальность местоположения ; распределение плотностей ; дифференциальная конфиденциальность ; геонетличность



Образец цитирования: Ким Дж. Улучшение данных
Угилит для сбора данных о местоположении с
сохранением конфиденциальности с помощью
адаптивного разделения сетки. Электроника 2024,
13, 3073. <https://doi.org/10.3390/electronics13153073>

Академические редакторы: Свапниль Рой и Гоша Н
Сюй

Поступила: 27 июня 2024 г.

Пересмотрено: 27 июля 2024 г.

Принято: 29 июля 2024 г.

Опубликовано: 3 августа 2024 г.



Копирйт: © 2024 авторы.
Лицензия: 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

Распространение устройств с поддержкой GPS и последние достижения в технологиях позиционирования упростили сбор данных о местоположении пользователей, что сделало их ценным активом для различных секторов. Эти данные играют важную роль в таких областях, как персонализированный маркетинг, анализ трафика в реальном времени, рекомендации и т. д. Например, анализ трафика в реальном времени использует данные о местоположении для оптимизации транспортных потоков, уменьшения задержек и улучшения навигационных систем для более эффективного передвижения [1,2]. Кроме того, рекомендации по услугам ресторанами мероприятия на основе местоположения предоставляют пользователям актуальные и своевременные предложения, используя их общий опыт [3,4]. В результате спрос на сбор и обмен данными о местоположении пользователей продолжает расти.

Данные о местонахождении пользователей являются конфиденциальными, поскольку они содержат личную информацию, такую как домашний адрес или адрес компании, записи о посещениях больницы и даже политическую принадлежность [5–7]. Например, собирая и анализируя информацию о местоположении посетителей в большем масштабе, например, в центре, можно получить конфиденциальные данные, такие как их модели совершения покупок. Кроме того, данные о местоположении можно сопоставить с другими наборами данных, чтобы сделать еще более точные выводы об образе жизни и благополучии человека [8]. Например, частые посещения определенных видов предприятий или мест могут указывать на конкретное состояние здоровья, хобби или даже религиозные верования. В результате неизбежны проблемы с конфиденциальностью сбора данных о местоположении пользователей. Следовательно, были предприняты значительные усилия для защиты конфиденциальности данных о местоположении пользователей при обработке таких данных.

Поскольку дифференциальная конфиденциальность (DP) [9,10] стала стандартом де-факто для обработки конфиденциальных персональных данных, были предприняты значительные усилия по его применению к данным о местоположении. В результате было предложено множество методов на основе DP для сбора, обработки и анализа данных о местоположении с сохранением конфиденциальности. Многие из этих подходов представляют данные о местоположении пользователей с помощью сеток, где весь домен равномерно разделен на пересекающиеся части.

сетки, а местоположение пользователя предстает сеткой, в которой находится его фактическое положение [11–14]. Хотя представление местоположения пользователя с использованием равномерных разделенных сеток является простым, оно не учитывает фактическое распределение пользователей в пространстве. Этот подход часто приводит к снижению полезности собранных данных о местоположении, поскольку предполагается, что пользователи равномерно и равномерно распределены по территории. Однако это не так в большинстве реальных сценариев, где некоторые области более плотные, чем другие. Например, в городской среде в центре города может быть высокая концентрация пользователей, а в пригороде — меньшая плотность. Это несоответствие может негативно повлиять на точность и эффективность последующих анализов. Поэтому для улучшения использования данных и повышения производительности этих приложений необходимы более сложные представления в виде сетки, соответствующие реальному распределению пользователей.

Существующие решения предполагают наличие предварительной информации о распределении пользователей, обычно получаемой из исторических данных. Однако такие исторические данные не всегда могут быть доступны для многих приложений. Что еще более важно, предварительная информация о распределении пользователей, полученная на основе исторических данных, может не соответствовать текущему распределению, поскольку оно может меняться со временем из-за изменений в особые социальные события. Например, крупные события, такие как фестивали, могут кардинально изменить модели и плотность передвижения пользователей, делая исторические данные устаревшими или вводящими в заблуждение [15]. Поэтому предпочтительно мгновенно извлекать информацию о распределении пользователей во время сбора данных и соответствующим образом адаптивно корректировать сетку.

В этой статье мы предлагаем новый метод, который одновременно извлекает распределение пользователей и адаптивно настраивает сетку в режиме реального времени во время сбора данных о местоположении. Вклад этой работы можно резюмировать следующим образом:

- Во-первых, мы представляем метод эффективного расчета распределения пользователей во время сбора данных о местоположении на основе DP. Этот подход позволяет эффективно отслеживать распределение пользователей в режиме реального времени и адаптировать сетку динамически в зависимости от поведения пользователей. Затем мы предлагаем адаптивную настройку сетки, чтобы максимизировать полезность собранных данных о местоположении в рамках DP. Эта адаптивная корректировка сетки предназначена для повышения детализации и актуальности данных, гарантируя, что наиболее важные моменты сценария настраиваются от дан приоритет, тем самым улучшая общие качества и применимость данных. Мы оценили производительность предложенных алгоритмов, используя реальные Результаты оценки показали, что предложенная схема значительно повышает полезность собранных данных о местоположении по сравнению с существующими методами. Остальная часть статьи и организована следующим образом В разделе 2 рассматриваются соответствующие работы. В разделе 3 мы предоставляем справочную информацию. В разделе 4 мы представляем новый метод, который одновременно извлекает распределение пользователей и адаптивно корректирует сетку в режиме реального времени во время сбора данных о местоположении. В разделе 5 мы экспериментально оцениваем предлагаемый подход на реальных наборах данных. Наконец, в разделе 6 представлены наши выводы.

2. Соответствующая работа

Было разработано множество методов на основе DP для сбора, обработки и анализа данных о местоположении с сохранением конфиденциальности. В этом разделе мы даем краткий обзор этих методов.

Локальная дифференциальная конфиденциальность (LDP) — это вариант DP, в котором каждый пользователь локально изменяет свои конфиденциальные данные, прежде чем передать их на сервер. Кими Янг [12] предлагают подход агрегированию данных на основе LDP, предназначенный для сбора данных о местоположении внутри помещений с учетом рабочей нагрузки, обеспечивая при этом конфиденциальность пользователей. Их метод определяет оптимальную стратегию кодирования и искажения данных в рамках LDP, чтобы минимизировать общую ошибку оценки для данной рабочей нагрузки. LDPTrace [14] предназначен для синтетического генерирования локально дифференциальных частных данных от раектория. В этом методе информация о местоположении пользователя собирается с помощью LDP для обеспечения конфиденциальности, а затем эти искаженные данные используются для создания синтетических траекторий. Кими др. [3] представляют метод рекомендации следующего лучшего интереса, используя данные о местоположении, собранные в рамках LDP.

Метрическая дифференциальная конфиденциальность (MDP) расширяет стандартную структуру для дифференциальной конфиденциальности для обработки данных с помощью встроены метрических или дистанционных мер [16]. Это расширение особенно полезно для данных о местоположении. Гео-неотличимость (Geo-Ind) — это специфическое применение MDP, разработанное для услуг, основанных на местоположении [11,17,18]. Платформы Mobile Crowdsensing (MCS) часто используют Geo-Ind для сбора информации о местоположении от работников и назначения задач с сохранением конфиденциальности. Вани др. [19] был первым кто использовал Geo-Ind для защиты конфиденциальности местоположения работников в процессе MCS. Предложенная ими структура включает три шага: во-первых, сервер MCS генерирует функцию, удовлетворяющую Geo-Ind. Далее каждый работник загружает эту функцию, скрывает свое истинное местоположение и загружает скрытое местоположение на сервер. Наконец, сервер MCS назначает задачи работникам на основе загруженной информации о местоположении. В [20] исследуется защита конфиденциальности местоположения в MCS на базе транспортных средств, где дорожная карта моделируется как взвешенный ориентированный граф с местоположениями задачи работников в виде точек на графике. Авторы предлагают схему запутывания на основе механизма оптимизации, которая обеспечивает запутывание местоположения посредством вероятностного распределения по графу, удовлетворяющего Geo-Ind. Джини др. [21] предлагает ориентированную на пользуетеля структуру торговли конфиденциальностью местоположения для MCS. Следуя концепции Geo-Ind, они разрабатывают механизм запутывания местоположения, который позволяет каждому работнику вероятностно скрывать свое истинное местоположение, используя свой собственный бюджет конфиденциальности. Чжани др. [13] представляет метод запутывания, который позволяет Geo-Ind собирать информацию о местоположении от работников MCS. Хуанг и др. [22] предлагают схему мониторинга шума на основе MCS, обеспечивающую конфиденциальность, при которой сервер публикует задачи, а работники сообщают о нарушенных местоположениях и уровнях шума в рамках DP. Каждый работник сотрудничает с мастером, чтобы выбрать минимальное количество работников одной группы, для достижения Гео-Инд на уровне группы. Чжао и др. [23] исследовали защиту конфиденциальности местонахождения отдельных лиц в контексте анализа географического на правленного распределения сообщества. Они определили информацию о сообществе с помощью ковариационной матрицы и интегрировали ее в предложенную неотличимость геоэллипса на основе Geo-Ind. Эта неразличимость геоэллипса обеспечивает измеримые гарантии конфиденциальности для мест в пространстве Малахановиса. Юи др. [24] подчеркили недостатки существующих механизмов запутывания местоположения на основе Geo-Ind, особенно когда пользуетели последовательно делятся своим местоположением с несколькими поставщиками LBS в течение длительного периода времени. Чтобы решить эту проблему, они представили PrivLocAd, систему, которая использует профилирование местоположения для создания запутанных местоположений, тем самым защищая конфиденциальность пользуетелей от мультитипатформенных состоятельных атак. Чжао и др. [25] представили новую концепцию конфиденциальности, называемую векторной неотличимостью, которая основана на G. Они разработали четыре механизма для достижения неотличимости и векторов, используя как распределение Лапласа, так и равномерное распределение. Мендес и др. [26] использовали скорость пользуетеля и частоту отчета для измерения корреляции между местоположениями. Они расширили Geo-Ind, чтобы улучшить сохранение конфиденциальности в сценариях непрерывной онлайн-отчетности. В частности, они представили систему Geo-Ind, учитывая скорость, которая автоматически балансирует конфиденциальность и полезность на основе скорости пользуетеля и частоты отчета о местоположении.

EGeoIndis [27] — это система защиты конфиденциальности местоположения транспортных средств, предназначенная для оценки плотности трафика. Она использует Geo-Ind для защиты конфиденциальности местоположения транспортных средств во время процесса оценки плотности трафика. В [28] авторы предложили метод, основанный на глобальном обучении, для оценки распределения плотности с использованием данных о местоположении, собранных с помощью GPS. Чени др. [29] разработали метод создания карты уязвимости к COVID-19 с использованием распределения плотности и участников-добровольцев с симптомами COVID-19. Они используют Geo-Ind для сбора данных о местонахождении участников с соблюдением конфиденциальности и обеспечения конфиденциальности и конфиденциальной медицинской информации. Фаталлизаде и др. [30] представляют основу для внедрения Geo-Ind в помещения. Предлагаемая структура рассматривает два сценария применения Geo-Ind, сообщая поставщику услуг определения местоположения запутанную точку, которая удовлетворяет требованиям MDP.

Предлагаемый в этой статье подход использует Geo-Ind, который является репрезентативной моделью в области сбора данных о местоположении с сохранением конфиденциальности. Однако предлагаемый подход отличается от других методов, основанных на Geo-Ind, по нескольким причинам. Во-первых, существующие

методы обычно полагаются на наличие исторических данных для определения распределения пользователей, что представляет собой серьезные проблемы. Исторические данные не всегда могут быть доступны или актуальными, что приводит к неточным выводам о распределении пользователей. Во-вторых, большинство существующих методов используют статистические структуры сетей, в результате чего получается фиксированное представление, не учитывающее динамическое перемещение пользователей. Напротив, предлагаемый метод устраняет эти ограничения за счет адаптивной настройки сетки в режиме реального времени во время сбора данных. Эта динамическая корректировка фиксирует текущее распределение пользователей, не полагаясь на исторические данные, тем самым повышая полезность собранных данных.

3. Предыстория и постановка проблемы

В этом разделе мы приводим необходимые основы для этой статьи и формулируем проблему, рассматриваемую в этой статье.

3.1. Предыстория

Недавно DP стал фактически стандартом обработки данных с сохранением конфиденциальности. DP основана на формальном математическом определении, которое обеспечивает верооятностную гарантию конфиденциальности от злоумышленников с произвольными базовыми знаниями [9]. Это гарантирует, что злоумышленник не сможет с высокой степенью достоверности определить, включен ли человек в распространяемые данные. DP формально определяется как [9,10]:

Определение 1. (ϵ -DP) Рандомизированный алгоритм M удовлетворяет ϵ -DP, если и только если для (1) любых двух соседних наборов данных D_1 и D_2 , и (2) любого выхода O из A выполняется следующее:

$$\Pr[A(D_1) = O] \leq e^\epsilon \times \Pr[A(D_2) = O]. \quad (1)$$

Два набора данных D_1 и D_2 считаются соседними, если они отличаются только одной записью. Приведенное выше определение указывает на то, что для любого вывода злоумышленник с любыми базовыми знаниями не может надежно определить, были ли D_1 или D_2 входными данными для A . Параметр ϵ , известный как бюджет конфиденциальности, регулирует уровень конфиденциальности: меньшие значения обеспечивают более сильную защиту конфиденциальности, но добавляют к результату больше шума, тогда как более высокие значения ϵ обеспечивают более слабую защиту конфиденциальности с меньшим количеством шума.

Было несколько предложений применить концепцию DP для защиты данных о местоположении. В этой статье мы используем Geo-Ind, концепцию, основанную на хорошо рекомендовавшей себя структуре ре DP и признанную стандартным определением конфиденциальности для защиты данных о местоположении в службах, основанных на местоположении [11,17,18]. Помимо данных о местоположении, Geo-Ind также используется для сбора других типов данных, таких как текстовые микроданные, в соответствии с требованиями DP [31,32].

Geo-Ind формально определяется следующим образом

Определение 2. (ϵ -Geo-Ind) Рассмотрим как набор возможных местоположений пользователей Y , а X как набор сообщений местоположений, которые обычно считаются равными. Пусть K — рандомизированный механизм, который генерирует искаженное местоположение на основе истинного местоположения пользователя. Рандомизированный механизм K удовлетворяет ϵ -Geo-Ind тогда и только тогда, когда следующее условие выполняется для (1) всех $x_1, x_2 \in X$ и (2) любого выходного местоположения $y \in Y$:

$$K(x_1)(y) \leq e^\epsilon \times K(x_2)(y), \text{ где } d(x_1, x_2) \leq \delta \quad (2)$$

соответствует расстоянию между x_1 и x_2 .

Существует два основных метода реализации Geo-Ind: механизм Лапласа и матричный механизм. Хорошо известно, что матричный механизм более эффективен, чем механизм Лапласа, при наличии априорной информации о распределении пользователей, которую можно получить из доступных исторических данных [11]. Такая повышенная эффективность обусловлена тем, что механизм на основе матрицы включает информацию о предварительном распределении при изменении истинного местоположения пользователей. В результате распределение возмущенных местоположений, собранное с использованием матричного механизма, более близко приближается к истинному распределению, чем распределение, полученное с использованием механизма Лапласа.

В матрично-механизме пространствосначаларазбиваетсяна наборсеток, а затемсерверсбораданныхвычисляетматрицуобфускацииМпоэтимсеткамкотяудовлетворяетe-Geo-Ind.Эта матрица затемраспространяетсясредипользователей.Впоследствиипользователиискажаютданныеосвоеместоположениивсоответствиисвероятностями,заложенными вМ, и сообщаютсерверуобискаженномместоположениивместосвоихистинныхданных.Влитературебылопредложенонесколькоподходовквычислениюматрицыобфускации,удовлетворяющейe-Geo-Ind [11,13,14,32,33].Однакоотметим,чтометодпредложенный вданнойстатье,являетсясамымобщим,чтобыегоможнобылоприменитьклюбомуматричномумеханизму.

3.2. Постановка задачи

Пусть $U = \{u_1, u_2, \dots, u_k\}$ — наборпользователей,которыесогласилисьпредоставитьсерверуинформациюосвоеместоположении.Однакопользователинеполностьюдоверяютсерверу, и поэтому вместо предоставления истинной информации о местоположении каждый пользователь предоставляет искаженную (и, следовательно, сохраняющую конфиденциальность) информацию о местоположении, которую удовлетворяет e-Geo-Ind. Предположим, что вся область разбита на непересекающиеся сетки, и пусть G — множество этих сеток. Местоположение каждого пользователя затемпредоставляетсясеткой в G , которой принадлежит его/ее истинное местоположение.

Проблема, рассматриваемая в этой статье, заключается в сборе полезных данных о местоположении при одновременной защите конфиденциальности местоположения пользователей с помощью e-Geo-Ind. Существующие методы либо используют статическое разделение по сетке, которое не адаптируется к изменениям в распределении пользователей в реальном времени, либо полагаются на уже существующие данные о распределении пользователей, которые могут быть недоступны или неточны в сценариях реального времени. Чтобы устранить эти пробелы, мы предлагаем новый метод разделения адаптивной сетки, который динамически корректирует сетку в процессе сбора данных о местоположении. В частности, предлагаемый метод напрямую фиксирует распределение пользователей во время сбора данных, устраняя необходимость в уже существующей информации о распространении.

4. Предлагаемый метод

На рисунке 1 представлено обзор предлагаемой схемы сбора данных о местоположении с использованием e-Geo-Ind.

- Сбор искаженных данных о местоположении от выбранных пользователей: сервер сначала вычисляет матрицу обфускации M по равномерно разделенным сеткам и распределяет ее среди выбранных пользователей, которые затем управляют своими искаженными местоположениями обратно на сервер.
- Оценка распределения пользователей: сервер оценивает распределение пользователей на основе искаженных данных о местоположении, полученных от выбранных пользователей. • Вычисление адаптивно разделенных сеток. Сервер использует предполагаемое распределение пользователей для расчета адаптивно разделенных сеток. • Сбор искаженных данных о местоположении от оставшихся пользователей с использованием адаптивно разделенных сеток: новая матрица запутывания вычисляется с использованием адаптивно разделенных сеток. Эта новая матрица затем используется для сбора данных о местоположении остальных пользователей.




Рисунок 1. Обзор предлагаемой схемы сбора данных о местоположении с сохранением конфиденциальности.

В следующих подразделах мы даем подробное объяснение каждого шага.

4.1. Сбор искаженных данных о местоположении от выборочных пользователей

Предположим, что вся площадь равномерно разбита на m сеток, $G = \{g_1, g_2, \dots, g_m\}$.

Сервер сбора данных вычисляет матрицу обфускации M над G . Существуют различные подходы к вычислению M , которые удовлетворяют ϵ -Geo-Ind. В данной статье мы используем метод, предложенный в [13], где матрица обфускации определяется как матрица размера $m \times m$. Каждый элемент $M[i, j]$, который представляет вероятность того, что возмущенное местоположение gj случайно генерируется из истинного местоположения gi , определяется следующим образом

$$M[i, j] = \frac{e^{-\frac{\epsilon}{2}} \cdot d(g_i, g_j)}{\sum_{g_k \in G} e^{-\frac{\epsilon}{2}} \cdot d(g_i, g_k)} \quad (3)$$

После вычисления матрицы запутывания M она распространяется среди выбранных пользователей, которые затем искажают свое истинное местоположение в соответствии с вероятностями, закодированными в M , и сообщают об искаженном местоположении на сервер.

4.2. Оценка распределения вероятностей

После сбора искаженных данных о местоположении выбранных пользователей следующим шагом будет оценка распределения пользователей на основе этих данных. Для каждой сетки gi пусть $P(gi)$ — вероятность того, что пользователь находится в точке gi . Затем в этом подразделе мы оцениваем $P(gi)$ для всех $gi \in G$ на основе выборочных возмущенных данных о

пусть I — местоположении. G — искаженные данные, которые сервер получает от выбранного gj , для пояснения, мы будем использовать g_j^I — пользователь. Для обозначения возмущенного местоположения gj для обозначения истинного местоположения. Вероятность того, что это возмущенное местоположение случайно генерируется из истинного местоположения $gi \in G$, можно вычислить следующим образом

$$P(g_i | g_j^I) = \frac{P(g_i)P(g_j^I | g_i)}{P(g_j^I)} = \frac{\prod_{g_i \in G} P(g_i)P(g_j^I | g_i)}{\prod_{g_k \in G} P(g_k)P(g_j^I | g_k)} = \frac{P(g_i)M[i, j]}{\prod_{g_k \in G} P(g_k)M[k, j]} \quad (4)$$

Заметим, что $P(g_j^I | g_i) = M[i, j]$ по определению матрицы обфускации. Поскольку невозможно вычислить априорную вероятность $P(g_i)$ непосредственно из приведенного выше уравнения, нам необходимо ее аппроксимировать. Существуют несколько методов аппроксимации априорной вероятности, включая вариационный вывод [34], цепь Маркова Монте-Карло [35] и распространение математического ожидания [36]. В этой статье мы используем алгоритм максимизации ожидания (ЕМ) [37] для оценки $P(g_i)$. Алгоритм ЕМ особенно эффективен, когда вероятность четко определена, что в нашем случае соответствует матрице обфускации M .

Пусть БД представляет собой пакет искаженных данных о местоположении выбранных пользователей. Процесс ЕМ для оценки $P(g_i)$ для всех $gi \in G$ из БД выглядит следующим образом

- Инициализация: параметр t (е. априорная вероятность) инициализируется следующим образом

$$P^{(0)}(g_1) = P^{(0)}(g_2) = \dots = P^{(0)}(g_m) = \frac{1}{m} \quad (5)$$

- Е-шаг: априорная вероятность рассчитывается на основе текущих параметров следующим образом

$$P^{(t)}(g_i | g_j^I) = \frac{P^{(t)}(g_i)M[i, j]}{\prod_{g_k \in G} P^{(t)}(g_k)M[k, j]} \quad (6)$$

- М-шаг: параметр обновляется с использованием текущих априорных вероятностей, рассчитанных на предыдущем Е-шаге:

$$P^{(t+1)}(g_i) = \frac{g_j^I \cdot \sum_{j \in G} P^{(t)}(g_j | g_j^I)}{|БД|} \quad (7)$$

Здесь $|БД|$ представляет количество данных в БД. После обновления априорных вероятностей мы выполняем нормализацию, чтобы гарантировать, что сумма всех априорных вероятностей равна 1 следующим образом

$$P(t+1)(g_i) = \frac{P(t+1)(g_i)}{\sum_{g_k \in G} P(t+1)(g_k)} \quad (8)$$

Выше упомянутые E-шаг и M-шаг повторяются до тех пор, пока параметр не достигнет стабильного значения или пока количество итераций не достигнет заранее определенного порога.

4.3. Вычисление адаптивно разделенных сеток

В этом подразделе мы представляем метод, который адаптивно разбивает сетки на основе распределения вероятностей (т.е. $P(g_i)$ для всех $g_i \in G$), вычисленного на предыдущем этапе. Первоначально предлагаемый метод рассматривает все сетки в G как одинаковые сетки, а затем итеративно разбивает эту кластер сверху вниз, используя жадный алгоритм.

Пусть $GCv = \{C_1, C_2, \dots, C_{|GCv|}\}$ представляет собой набор кластеров сетки после v -го разбиения. Предположим, что для каждого $C_k \in GCv$ $Grid(C_k)$ обозначает множество сеток, принадлежащих кластеру C_k . Пусть n — общее количество пользователей, от которых сервер собирает данные о местоположении. Затем ожидаемое количество пользователей, расположенных в сетке g_i , вычисляется как $Cnt(g_i) = n \cdot P(g_i)$.

Более того, пусть $MGCv = |GCv| \times |GCv|$ матрица обфускации, удовлетворяющая Geo-Ind, построенная по элементам GCv с использованием уравнения (3). Расстояние между любыми двумя кластерами, необходимое для вычисления $MGCv$, определяется с использованием центроидов сеток, принадлежащих каждому кластеру. Затем предполагая, что пользователи искажают свое местоположение в соответствии с вероятностями, закодированными в $MGCv$, ожидаемое количество искаженных данных о местоположении, соответствующих сеткам, принадлежащим C_k , от которых сервер получает пользователей, вычисляется следующим образом

$$Cnt_{pert}(C_k) = \sum_{C_j \in GCv} Cnt(g_i) \times M[j, k] \quad (9)$$

Пусть $Clus()$ будет функцией, которая принимает сетку в качестве входных данных и выводит кластер, которому принадлежит эта сетка. Предполагая, что пользователи равномерно распределены по сеткам внутри каждого кластера, ожидаемая ошибка из-за Geo-Ind с GCv вычисляется следующим образом

$$Err_{GCv} = \sum_{g_i \in G} Cnt(g_i) - \frac{Cnt_{pert}(Clus(g_i))}{размер(Clus(g_i))} \quad (10)$$

Здесь $size(C_k)$ обозначает количество сеток, принадлежащих кластеру C_k .

Предположим, что в следующем $(v+1)$ -м разбиении $Ch \in GCv$ выбрана для разделения на подкластеры. В этой статье мы разделяем Ch на четыре подкластера одинакового размера, разделив ее на четыре области по горизонтали и вертикали. Пусть G_{Ch}^{v+1} представляет собой набор кластеров сетки, вновь полученных путем разделения Ch . Используя описанный выше метод, мы можем логично уменьшить ожидаемую ошибку $Err_{G_{Ch}^{v+1}}$. Набор кластеров сетки для $(v+1)$ -й итерации определяется следующим образом

$$GCv+1 = \underset{1 \leq h \leq |GCv|}{\operatorname{argmax}} \sum_{g_i \in G_{Ch}^{v+1}} Err_{g_i} \quad (11)$$

Другими словами, кластер сетки Ch , который обеспечивает максимальный коэффициент уменьшения ошибок, равен выбран для разделения на следующие итерации.

Алгоритм 1 представляет собой псевдокод для адаптивного разделения сеток с использованием распределения вероятностей пользователей. Алгоритм принимает на вход набор сеток G и распределения вероятностей $P(g_1), \dots, P(g_m)$ и выводит набор кластеров сеток GC . В строке 1 инициализируется GC_{cur} , содержащий один кластер, включающий все сетки в G . Затем в строке 3 $Err_{GC_{cur}}$ вычисляется с использованием GC_{cur} . Между строками 4 и 12 алгоритм идентифицирует кластер $Ch \in GC_{cur}$, который дает максимальный выигрыш по уменьшению ошибок. Этот процесс повторяется до тех пор, пока коэффициент уменьшения ошибок не станет больше 0. Наконец, алгоритм возвращает GC_{cur} .

Алгоритм 1: Псевдокод для ввода адаптивного разделения

```
сет ки:  $G = \{g_1, \dots, g_m\}$  и  $P(g_i)$  для всех  $g_i \in G$ , выход:
набор кластеров сет ки GC
1. Инициализировать
GCcur; 2 пока правда, делая
3   ErrGCcur = EstimateErr(GCcur, MGCcur);
4   Idx = 0, Gainbest = 0; для h = 1
5   до |GCcur| делая
6     ГЧh = PartitionGrid(GCcur, h);
7     ЭррГЧh = EstimateErr(ГЧh p, MГЧh);
8     если (ЭррГЧh < ErrGCcur) > Gainbest, тогда
9       Идкс = h;
10      Gainbest = ЭррГЧh;
11    конец
12  конец
13  если Gainbest > 0, то
14    GCcur = GIdx;
15  иначе
16    сломать
17  конец
18  конец
19  возврат GCcur;
```

Предлагаемый в этом подразделе метод разделения адаптивной сетки основан на распределении вероятностей пользователей, оцененном на основе выборочных данных. Таким образом как и в случае с другими методами, основанными на выборке, существует вероятность того, что выборочные данные могут быть необъективными. Такие смещения могут привести к тому, что для разделения по сетке будут использоваться нерепрезентативное распределение пользователей, что может привести к неэффективному секционированию. Это, в свою очередь, может отрицательно повлиять на общую полезность собранных данных о местоположении, поскольку адаптивные сетки могут не только отражать истинную плотность пользователей, но и потенциально предвзятости и неочечность при сборе данных о распределении пользователей в реальном времени, в процессе выборки можно учитывать пространственные вариации. Одним из эффективных методов является использование статифицированной выборки [38], которая предполагает разделение всего региона на непересекающиеся субрегионы. Обеспечивая пропорциональное представительство каждого субрегиона в выборке, статифицированная выборка помогает уменьшить систематическую ошибку выборки и обеспечивает более точную оценку распределения пользователей.

4.4. Сбор данных о возмущении местоположения от оставшихся пользователей с использованием адаптивно

секционированных сеток. Новая матрица запутывания M вычисляется с использованием адаптивно секционированного набора сеток GC, вычисленного на предыдущем этапе. Адаптивно разделенные сетки обеспечивают более точный и релевантный процесс запутывания, более эффективно фиксируя динамический характер распределения пользователей, чем статические сетки. Как только новая матрица запутывания вычислена, она распространяется среди оставшихся пользователей. Затем эти пользователи используют обновленную матрицу, чтобы исказить данные о своем местоположении, гарантируя сохранение их конфиденциальности и соответствие с принципами Geo-Ind. Затем запутанные данные о местоположении отправляются обратно на сервер, где они интегрируются с ранее собранными данными от выбранных пользователей.

5. Эксперименты В

В этом разделе мы сначала опишем экспериментальную установку. Затем мы обсудим результаты экспериментов.

5.1. Экспериментальная

Установка В этом разделе мы описываем эксперименты, которые мы провели для оценки предлагаемого подхода. Для наших экспериментов мы использовали набор данных траекторий такси Порт-О [39], который

состоит из траекторий такси, состоящих из серии координат GPS, записанных с 442 такси, работающих в городе Порту, Португалия. Мы случайно образомизвлекли 50 000 данных о местоположении из этих траекторий, из которых 10 000 считались данными о местоположении выбранных пользователей. В эксперименте мы варьировали количество сеток от 400 (т.е. сетка 20 на 20) до 10 000 (т.е. сетка 100 на 100). В экспериментах сообщаются результаты для следующих альтернатив: существующего метода неадаптивной сетки (NG) в [13] и метода адаптивной сетки (AG), представленного в этой статье. Для оценки мы используем следующие метрики: • Метрика уровня данных измеряет сходство между набором данных истинного местоположения и набором данных искаженного местоположения, собранного с помощью Geo-Ind. Для оценки уровня данных мы используем среднюю ошибку подсчета (ACE), так и ошибку плотности. Средняя ошибка подсчета определяет разницу между фактическим количеством пользователей $\text{numtrue}(gi)$ и числом полученных из искаженного набора данных, $\text{numpert}(gi)$ для каждой сетки. Это рассчитано как

$$\text{Средняя ошибка подсчета} = \frac{1}{m} \sum_{i=1}^m \frac{|\text{номеристина}(gi) - \text{номер}(gi)|}{\text{Макс}(\text{числоистина}(gi), 1)} \quad (12)$$

Ошибка плотности измеряет разницу между фактической плотностью распределения пользователей и возмущенной версией, рассчитанной на основе наборов данных, собранных в рамках Geo-Ind. Эта ошибка измеряется как

$$\text{Ошибка плотности} = \text{JSD}(D(OD), D(PD)) \quad (13)$$

Здесь $\text{JSD}()$ представляет собой расхождение Джансона-Шеннона между двумя распределениями из исходного набора данных о местоположении, $D(OD)$ и из возмущенного набора данных о местоположении, $D(PD)$.

- Метрика уровня приложения оценивает полезность собранных данных с точки зрения приложений, которые их используют. Для этой метрики мы используем ошибку запроса диапазона, широко признанную меру эффективности данных о местоположении [14]. В эксперименте мы генерируем запрос диапазона QR случайной областью R и сравниваем количество результатов из исходного набора данных о местоположении QR (OD) с результатами из искаженных наборов данных о местоположении QR (PD). Она рассчитывается как

$$\text{Ошибка запроса диапазона} = \frac{|\text{QR}(OD) - \text{QR}(PD)|}{\max(\text{QR}(OD), 1)} \quad (14)$$

В ходе экспериментов мы сгенерировали 200 запросов диапазона и сообщили о средней ошибке запроса диапазона.

В эксперименте использовались различные бюджетные конфиденциальности (ϵ) в диапазоне от 0,2 до 2,0. Бюджет конфиденциальности менее 2 обычно считается приемлемым для практических приложений [14]. Мы реализовали NG и AG с использованием Python 3.8, и все эксперименты проводились в среде, оснащенной процессорами Intel Xeon 5220R и 64 Мб памяти.

5.2. Результаты

В этом подразделе мы сначала представляем результаты оценки уровня данных, а затем представляем результаты оценки уровня приложения.

5.2.1. Оценка на уровне данных

На рисунке 2 показано влияние бюджета конфиденциальности как на среднюю ошибку подсчета, так и на ошибку плотности. В этом эксперименте бюджет конфиденциальности варьируется от 0,2 до 2,0, а размер сетки фиксирован на уровне 400. При уменьшении обеих ошибок увеличивается. Это связано с тем, что по мере уменьшения степени возмущения, вызванного Geo-Ind, увеличивается, что приводит к увеличению ошибки, что обычно наблюдается при использовании методов, основанных на DP. Как показано на рисунках, предлагаемый метод (AG) стабильно превосходит существующий метод (NG) на всех уровнях бюджета конфиденциальности. Более того, разрыв в производительности между этими двумя методами увеличивается по мере того, как конфиденциальность

бюджет уменьшается, а значит и уровень конфиденциальности возрастает. Это показывает, что предлагаемый метод более выгоден для приложений, требующих высокого уровня конфиденциальности, что типично для большинства приложений, обрабатывающих данные о местоположении.




Рисунок 2. Влияние бюджета конфиденциальности на (а) среднюю ошибку подсчета и (б) ошибку плотности для существующего метода неадаптивной сетки (NG) и предлагаемого метода адаптивной сетки (AG).

На рис. 3 показано влияние количества сеток на среднюю ошибку подсчета и ошибку плотности. В этом эксперименте количество сеток варьируется от 400 до 10 000, при этом бюджет конфиденциальности фиксирован на уровне 0.6. Из рисунка видно, что предлагаемый способ последовательно превосходит существующий метод для всех размеров сетки. Более конкретно, как видно из рисунка, средняя ошибка подсчета уменьшается с увеличением количества сеток. Обратите внимание, что по мере увеличения количества сеток количество точек в сетке уменьшается, поэтому общее количество точек в сетке фиксировано. Это, в свою очередь, уменьшает среднюю ошибку подсчета, которая основана на абсолютной разнице между количеством точек, полученная на основе фактических данных о местоположении и искаженные данные о местоположении. С другой стороны, с увеличением количества сеток плотность ошибки, которая измеряет расхождение Джессона-Шеннона между двумя распределениями исходных данных о местоположении и борными измененными данными о местоположении, увеличивается. Это потому, что Расхождение Джессона-Шеннона измеряет относительную разницу между распределениями и, следовательно, на него не влияет количество точек в каждой сетке. По мере того как размер сетки становится меньше, возмущения в данных оказывают более выраженное влияние на распределение, в результате чего в более высокоточном расхождении между исходными и искаженными данными.




Рис. 3. Влияние количества сеток на (а) среднюю ошибку подсчета и (б) ошибку плотности для существующего метода неадаптивной сетки (NG) и предлагаемого метода адаптивной сетки (AG).

Результаты, представленные на рисунках 2 и 3, подтверждают, что предложенный метод позволяет собирать данные о местоположении, которые больше похожи на исходные данные в Geo-Ind, чем существующий метод. Эти результаты подчеркивают существенные преимущества нашего подхода.

в сборе данных о местоположении с сохранением конфиденциальности. Динамически корректируя сетки на основе распределения пользователей в реальном времени в Geo-Ind, мы достигаем более высокой точности и полезности данных.

5.2.2. Оценка на уровне приложения На рисунке 4

показано влияние бюджета конфиденциальности и количества сеток на ошибку запроса диапазона. На рисунке 4а размер сетки фиксирован на уровне 400, а на рисунке 4б бюджет конфиденциальности фиксирован на уровне 0,6. Как показано на рисунке, с уменьшением ошибки, связанная с использованием метода резко возрастает, в то время как ошибка предлагаемого метода увеличивается лишь незначительно. Это происходит потому, что предлагаемый метод способен собирать наборы данных о местоположении, которые ближе к исходным наборам данных, что подтверждается оценкой на уровне данных.

Надежность нашего подхода при различных бюджетах конфиденциальности подчеркивает его эффективность в балансе конфиденциальности и точности. Поскольку устанавливается меньше, что указывает на более сильные гарантии конфиденциальности, предлагаемому методу все же удается сохранить полезность данных, что делает их более надежными для приложений, требующих точной информации о местоположении.

Более того, предлагаемый метод последовательно превосходит существующий метод на всех размерах сетки. Это подтверждает, что предложенный нами метод является надежным независимо от количества сеток. Способность поддерживать низкий уровень ошибок запросов в различных конфигурациях сетки демонстрирует адаптивность и эффективность нашего подхода. Эта надежность имеет решающее значение для практических приложений, которые требуют различных детализаций представления местоположения пользователя (т.е. количества сеток) в зависимости от требований приложения.

Экспериментальные результаты показывают, что предлагаемый метод может использоваться для широкого спектра услуг и приложений, основанных на определении местоположения, требующих разных уровней конфиденциальности и детализации при представлении местоположения пользователя.




Рисунок 4. Влияние (а) бюджета конфиденциальности и (б) количества сеток на ошибку запроса диапазона для существующего метода неадаптивной сетки (NG) и предлагаемого метода адаптивной сетки (AG).

5.2.3. Оценка изменчивости сетки и эффективности адаптации к сетке и Все

результаты экспериментов в предыдущих подразделах были получены в предположении, что условия сетки стабильны. Однако в реальных сценариях условия сетки могут быть весьма изменчивыми и непредсказуемыми. Предлагаемый метод адаптивно разбивает сетку на основе выборочных данных о местоположении, собранных в процессе сбора данных о местоположении. Однако нестабильные условия сетки, такие как высокая задержка в сети, потеря пакетов и низкая пропускная способность, могут задержать своевременный сбор этих выборочных данных. В результате некоторые выборочные данные могут быть недоступны для расчета адаптивного разделения сетки, что может привести к менее точному разбиению.

В этом подразделе для решения проблем нестабильных сеток мы оцениваем эффективность предлагаемого метода в реальных сетевых сценариях. В эксперименте, показанном в таблице 1, рассматривается сценарий, в котором некоторые выборочные данные о местоположении, необходимые для оценки распределения пользователей в разделе 4.2 (которые затем используются для адаптивного расчета сегментов сетки в разделе 4.3), либо теряются, либо не получены вовремя из-за нестабильной сети.

такие условия, как высокая задержка, потеря пакетов и низкая пропускная способность. В этом эксперименте коэффициент потерь выборочных данных о местоположении варьируется от 1% до 20%, охватывая диапазон типичного количества желаемых условий. В эксперименте количество сеток установлено равным 400 и бюджет конфиденциальности установлен на уровне 0,6. Как показано в Таблице 1, даже несмотря на то, что уровень потерь от обранных данных о местоположении увеличивается с 1% до 20%, обе ошибки остаются стабильными с очень небольшими увеличениями. В частности, даже в тех же условиях сетки с уровнем потерь 20%, предлагаемый метод адаптивной сетки (AG) значительно превосходит по эффективности и адаптивности сетку (NG) метод. Эти результаты подтверждают надежность и эффективность предлагаемого метода в поддержании полезности данных в реальных сетевых сценариях с различными уровнями потерь данных из-за нестабильных условий сети.

Таблица 1. Влияние скорости и потерь выборочных данных о местоположении на среднюю ошибку подсчета и ошибку плотности.

		А Г				Н Г
Коэф ффициент пот ери вы бороч ны х дан ны х о мест ополо жении 0 %		1%	5%	10%	20%	
Средня я ошибка подсчет а	4.705	4,867	4.896	4.936	5.018	9,842
Ошибка плот ност и	0,319	0,321	0,328	0,336	0,341	0,440

Предлагаемый метод адаптивной настройки работает сетку во время процесса сбора данных о местоположении, что приводит к дополнительной задержке из-за вычисления затрат расчет адаптивной сетки. Таким образом, мы экспериментально оцениваем задержку, вносимую предлагаемым методом. В Таблице 2 показаны результаты задержки, вызванной адаптивной сеткой. Расчет по предлагаемому методу. В этом эксперименте количество сеток варьируется от 400 до 10 000, а бюджет конфиденциальности фиксирован на уровне 0,6. Как показано в таблице, задержка увеличивается по мере увеличения размера сетки. Это связано с тем, что по мере увеличения количества сеток количество итераций, необходимых для адаптивного разделения сеток, также увеличивается. Как результат, более крупные сетки требуют больше вычислений ресурсов, что приводит к более высокой задержке.

Таблица 2. Задержка, вызванная вычислением адаптивной сетки.

Размер сетки	20 × 20	40 × 40	60 × 60	80 × 80	100 × 100
Время выполнения (с)	4.10	17.41	43.12	139,56	439,56

Отметим, что хотя вычисление адаптивной сетки вносит дополнительную задержку, как показано в Таблице 2, это однократный процесс в рамках общего сбора данных о местоположении. Процедура. Таким образом, влияние этих накладных расходов на общее время обработки Сбор данных о местоположении ограничен. Кроме того, дополнительная задержка, вызванная вычислениями затрат на адаптивное разделение сетки, может быть уменьшена с помощью различных параллельных вычислений. Методы обработки. В частности, такие методы, как платформы распределенных вычислений [40,41] и ускорение графического процессора, могут значительно сократить время вычислений, тем самым снижая задержку. Распределяя рабочую нагрузку между несколькими процессорами, эти подходы могут повысить эффективность процесса адаптивного разделения сетки, гарантируя анализ данных в приложениях реального времени.

6. Выводы и будущая работа

В последнее время возрос спрос на сбор и распространение данных о местоположении. Учитывая конфиденциальность характеристик информации о местоположении пользователей, значительные усилия были созданы для обеспечения конфиденциальности и приватности дифференцируемые схемы, основанные на конфиденциальности, являются предпочтительным подходом. Однако эти схемы обычно представляют местоположение пользователей на равномерно разделенные сетки, которые часто не отражают истинное распределение пользователей в пространстве. В этой статье мы представили новый подход, который динамически корректирует сетку в режиме реального времени во время сбора данных о местоположении с помощью Geo-Ind, чтобы повысить полезность собранных данных. Предлагаемый метод фиксирует распределение пользователей непосредственно во время сбора данных. Сбор, устраняя зависимость от уже существующей информации о распространении. Экспериментально мы

Результаты на реальных данных подтвердили, что предложенная схема значительно повышает полезность собранных данных о местоположении как на уровне данных, так и на уровне приложений. В частности, результаты показали, что по сравнению с существующим решением предлагаемый метод может снизить частоту ошибок до 52% в экспериментах на уровне данных и до 75% в экспериментах на уровне приложения.

Несмотря на многообещающие результаты, предлагаемый метод имеет следующие ограничения. Поскольку предлагаемый метод адаптивно настраивает сетку в режиме реального времени во время сбора данных, возникают дополнительные вычислительные затраты, связанные с вычислением адаптивной сетки. Эти накладные расходы особенно значительны при использовании сетки большого размера. Таким образом, будущая работа будет сосредоточена на повышении эффективности и вычислительной адаптивности сетки, особенно для больших размеров сетки с большим количеством точек. Этого можно достичь за счет распараллеливания процесса разделения адаптивной сетки для уменьшения вычислительных затрат. Мы рассмотрим различные методы параллельной обработки, такие как реализация платформ распределенных вычислений, таких как Apache Hadoop [40] или Apache Spark [41], которые распределяют данные и вычисления по кластеру машин. Кроме того, можно рассмотреть многопоточность на одной машине и использование ускорения графического процессора для повышения эффективности. Кроме того, интеграция сервисов облачных вычислений увеличивает масштабируемость за счет предоставления динамической и масштабируемой инфраструктуры для выполнения адаптивного разделения сетки на больших бордах.

Еще одним будущим направлением исследований является теоретический анализ влияния адаптивного разделения сетки на полезность собранных данных о местоположении. Этот анализ выявляет основные принципы адаптивного разделения сетки и его влияние на полезность данных, тем самым обеспечивая более надежную теоретическую поддержку предлагаемого метода. Кроме того, можно дополнительно изучить компромисс между конфиденциальностью и полезностью, чтобы оптимизировать баланс между конфиденциальностью и полезностью. Это будет включать разработку моделей и показателей для количественной оценки этого компромисса в различных условиях.

Финансирование: Это исследование финансировалось за счет исследовательского гранта Университета Саньчжэна 2023 год (2023-A000-0119).

Заявление о доступности данных. Исходные данные, представленные в исследовании, находятся в открытом доступе в Kaggle по адресу <https://www.kaggle.com/c/pkdd-15-predict-taxi-service-trajectory-i>. (по состоянию на 20 июня 2024 г.).

Конфликт интересов: Автор заявляет об отсутствии конфликта интересов.

Сокращения

В данной рукописи использованы следующие сокращения:

ДП	Дифференциальная конфиденциальность
ЛДП	Локальная дифференциальная конфиденциальность
Дифференциальная конфиденциальность показателей MDP	
Гео-индия	Гео-неотличимость
МКС	Мобильный краудсенсинг
ЭМ	Ожидание-Максимизация
JSD	Дивергенция Джессона-Шеннона

Рекомендации

- Ван Х.; Мэжт.; Ван Ю. Джин, В.; Ван Х.; Тан Дж.; Цзя, К.; Ю. Дж. Прогнозирование транспортных потоков с помощью нейронного пространственно-временного графа сеть. В материалах веб-конференции, Тайбэй, Тайвань, 20–24 апреля 2020 г.; стр. 1082–1092.
- Пан З.; Лян Ю. Ван В.; Ю. Ю. Чжэнь, Ю. Чжан Дж. Прогнозирование городского трафика на основе пространственно-временных данных с использованием лобного метода обучения. В материалах Международной конференции ACM SIGKDD по обнаружению знаний и интеллектуальному анализу данных, Анкоридж, штат Алабама, США, 4–8 апреля 2019 г.; стр. 1720–1730.
- Ким Дж.С.; Ким JW; Чунг, ЮД. Последовательные рекомендации по локальной дифференциальной конфиденциальности. Доступ IEEE 2021, 9, 66371–66386. [\[Перекрестная ссылка\]](#)
- Ан Дж.; Ли, Г.; Цзянь В. NRDL: Децентрализованное изучение предпочтений пользователей для сохранения конфиденциальности и следующих рекомендаций POI. Эксперт Сист. Прил. 2024, 239, 122421. [\[CrossRef\]](#)
- Примо, В.; Буте, А.; Мохтар, СБ; Бруни, Л. Долгий путь к конфиденциальности и вычислительного местоположения: опрос. IEEE-сообщество. Выж. Репетитор. 2019, 21, 2772–2793. [\[Перекрестная ссылка\]](#)

6. Лю, Б.; Чжоу, В.; Чжу, Т.; Гао, Л.; Сян, Ю. Конфиденциальность местоположения и ее применение: систематическое исследование. *IEEE Access* 2019, 6, 17606–17624. [\[Перекрестная ссылка\]](#)

7. Альхарт, Р.; Банхрани, А.; Альзахрани, А.; Альшехри, А.; Альшахрани, Х.; Фу, Х.; Лю, А.; Чжу, Ю. Проблемы конфиденциальности местоположения в беспроводном краудсорсинге. В материалах Междунароной конференции IEEE по электронным технологиям Рочестер, Мичиган, США, 3–5 мая 2018 г.

8. Хенриксен-Балмер, Дж.; Джери, С. Атаки повторной идентификации – систематический обзор литературы. *Межд. Ж. Инф. Менеджер.* 2016, 36, 1184–1192. [\[Перекрестная ссылка\]](#)

9. Дворк, К. Дифференциальная конфиденциальность. В материалах Междунароного коллоквиума по автоматизации языками программированию, Венеция, Италия, 10–14 июля 2006 г.; стр. 1–12.

10. Дворк, К.; МакШерри, Ф.; Ниссим, К.; Смит, А. Калибровка шумов чувствительности и анализ частых данных. В материалах Третья конференция по теории криптографии, Нью-Йорк, США, 4–7 марта 2006 г.

11. Борденабе, Невада; Хациколакис, К.; Паламидес, К. Оптимальные геонезначимые механизмы обеспечения конфиденциальности местоположения. В материалах конференции ACM SIGSAC по компьютерной и коммуникационной безопасности, Нью-Йорк, штат Нью-Йорк, США, 3–7 ноября 2014 г.; стр. 251–262.

12. Ким, Дж.; Джанг, Б. Сбор данных о местоположении внутри помещений с учетом обочай нагрязки с помощью локальной дифференциальной конфиденциальности. *IEEE-сообщения. Летт.* 2019, 23, 1352–1356. [\[Перекрестная ссылка\]](#)

13. Чжан, П.; Ченг, Х.; Су, С.; Ван, Н. Наблюдение на основе терриоризации охватывающих географической неопределенности. *Вычислит. Сеть.* 2022, 217, 109340. [\[CrossRef\]](#)

14. Ду, Ю.Ху, Ю.Чжан, З.; Фанг, З.; Чен, Л.; Чжан, Б.; Гао, Ю. LDPTrase: Синтез локального дифференциального частых траекторий. В материалах Фонда VLDB, Ванкувер, Британская Колумбия, Канада, 28 августа – 1 сентября 2023 г.; стр. 1897–1909.

15. Гаеми, З.; Фарнаги, М. Подход кластеризации на основе различной плотности для обнаружения событий на основе гетерогенных данных. *Твиттер. ISPRS Int. Дж. Гео-Инф.* 2019, 8, 82. [\[CrossRef\]](#)

16. Алвим, М.; Хациколакис, К.; Паламидес, К.; Пазис, А. Локальная дифференциальная конфиденциальность в метрических пространствах: оптимизация компромисса с полезностью. В материалах симпозиума IEEE по основам компьютерной безопасности, Оксфорд, Великобритания, 9–12 июля 2018 г.

17. Андрес, М.; Борденабе, Небраска; Хациколакис, К.; Паламидес, К. Геонеприличность: дифференциальная конфиденциальность для систем основанных на определении местоположения. В материалах конференции ACM SIGSAC по компьютерной и коммуникационной безопасности, Берлин, Германия, 4–8 ноября 2013 г.; стр. 901–914.

18. Хациколакис, К.; Паламидес, К.; Стронати, М. Геонеприличность: принципальный подход к конфиденциальности местоположения. В материалах Междунароной конференции по распределенным вычислениям и интернет-технологиям Бхубанешвар, Индия, 5–8 февраля 2015 г.; стр. 49–72.

19. Ван, Л.; Ян, Д.; Хан, Х.; Ван, Т.; Чжан, Д.; Ми, Х. Распределение задач по сохранению конфиденциальности местоположения для мобильного краудсорсинга с дифференциальной геообфускацией. В материалах Междунароной конференции по всемирной паутине, Перт, Австралия, 3–7 апреля 2017 г.; стр. 627–636.

20. Цю, К.; Сквичини, А. Защита конфиденциальности местоположения в беспроводном краудсорсинге на основе транспортных средств посредством географической неопределенности. В материалах Междунароной конференции IEEE по распределенным вычислениям и системам Деллас, Техас, США, 7–10 июля 2019 г.; стр. 1061–1071.

21. Джин, В.; Сяо, М.; Го, Л.; Ян, Л.; Ли, М. ULPT: Ориентированная на пользвателя система торговли конфиденциальностью местоположения для мобильного зондирования толпы. *IEEE Транс. Моб. Вычислит.* 2022, 21, 3789–3806. [\[Перекрестная ссылка\]](#)

22. Хуан, П.; Чжан, Х.; Го, Л.; Ли, М. Стимулирование мониторинга шумов на основе краудсорсинга в дифференциальном частых местах. *IEEE Транс. Моб. Вычислит.* 2021, 20, 519–532. [\[Перекрестная ссылка\]](#)

23. Чжао, Ю. Янь, Д.; Ду, Джей. Т.; Чен, Дж. Гео-эллипс-неразличимость: защита конфиденциальности местоположения с учетом сообщений для направленного распределения. *IEEE Транс. Знать. Данные* 2023, 35, 6957–6967. [\[Перекрестная ссылка\]](#)

24. Ю.Л.; Чжан, С.; Ми, Ю. Ду, С.; Чен, Ю. Рен, Ю. Чжу, Х. Реклама на основе местоположения, сохраняющая конфиденциальность посредством продольной геонеприличности. *IEEE Транс. Моб. Вычислит.* 2024, 23, 8256–8273. [\[Перекрестная ссылка\]](#)

25. Чжао, Ю. Чен, Дж. Неразличимость векторов: защита конфиденциальности на основе зависимости местоположения для последовательных данных о местоположении. *IEEE Пер. Вычислит.* 2024, 73, 970–979. [\[Перекрестная ссылка\]](#)

26. Мендес, Р.; Куныя, М.; Вилела, Дж. П. Географическая неопределенность с учетом скорости. В материалах конференции ACM по данным Безопасности и конфиденциальности приложений, Шарлотт, Северная Каролина, США, 24–26 апреля 2023 г.; стр. 141–152.

27. Рен, В.; Тан, С. Э. ГеоИндекс: Эффективная и действенная система защиты конфиденциальности местоположения при обнаружении плотности трафика. *Вех. Кому.* 2020, 21, 100187. [\[CrossRef\]](#)

28. Ким, Дж.В.; Лим, Б. Эффективная и сохраняющая конфиденциальность оценка распределения плотности и пользвателей LBS в условиях геонеприличности. *Электроника* 2023, 12, 917. [\[CrossRef\]](#)

29. Чен, Р.; Ли, Л.; Мюжт; Гонг, Ю. Го, Ю. Оук, Т.; Гун, М. Построение мобильной краудсорсинговой карты уязвимости COVID-19. *С геонеприличностью. IEEE Internet Things J.* 2022, 9, 17403–17416. [\[Перекрестная ссылка\]](#)

30. Фатализаде, А.; Мохтади, В.; Алишахи, М. Геонеприличность в помещении: принятие дифференцированной конфиденциальности для помещений. *Защита данных о местоположении. IEEE Транс. Жест. Вершина. Вычислит.* 2023, 12, 293–306. [\[Перекрестная ссылка\]](#)

31. Фейсиган, О.; Балле, Б.; Дрейк, Т.; Дит, Т. Текстовый анализ, сохраняющий конфиденциальность и полезность, посредством калиброванных многомерных возмущений. В материалах Междунароной конференции по вебпоиску и интеллектуальному анализу данных, Хьюстон, Техас, США, 3–7 февраля 2020 г.; стр. 178–186.

32. Песня, С.; Ким Дж. В. Адаптация геонетличимост и для сбора медицинских микроданных с сохранением конфиденциальности. *Электроника* 2023, 12, 2793. [\[CrossRef\]](#)

33. Ахунджа, Р.; Гинит, Г.; Шахаби, К. Сохраняющий утилиты и масштабируемый метод защиты данных о местоположении с помощью геонетличимости. В *Материалах Междунароной конференции по расширению технологий баз данных*, Лиссабон, Португа, 26–29 марта 2019 г.; стр. 210–231.

34. Блей, Д.М.; Кукульбир, А.; МакОлифф, Дж. Д. Вариационный вывод: обзор для статистиков. *Варень е. Стат. доц.* 2017, 112, 859–877. [\[Перекрестная ссылка\]](#)

35. Чиб, С. Методы Монте-Карло с цепями Маркова: вычисления и выводы. *Handb. Эконом* 2001, 5, 3569–3649.

36. Ли, Ю.Эрнандес-Лобато, JM; Тернер, Р.Э. Распространение стохастического ожидания. *arXiv* 2018, arXiv:1506.04132.

37. Саммакнежа, Н.; Чжао, Ю.Хуанг, Б. Обзор алгоритма максимизации ожидания в идентификации процессов, управляемых данными. *Дж. Управление процессами* 2019, 73, 123–136. [\[Перекрестная ссылка\]](#)

38. Хауэлл, ЧР; Су, В.; Нассель, АФ; Агнел, А.А.; Черрингтон, Алабама, стандартизированная случайная выборка на основе площади с использованием геопространственных данных. *технологии в опросе на уровне сообщества*. *BMC Public Health* 2020, 20, 1678. [\[CrossRef\]](#) [\[PubMed\]](#)

39. Мрейра-Матис, Л.; Гама, Дж.; Феррейра, М.; Мендес-Мрейра, Ж.; Дамас, Л. Прогнозирование спроса на такси и пассажиров с помощью поточковой передачи данных. *IEEE Транс. Интел. Трансп. Сист.* 2013, 14, 1393–1402. [\[Перекрестная ссылка\]](#)

40. АпацХадул. Доступно онлайн: <https://hadoop.apache.org/>. (по состоянию на 22 июля 2024 г.).

41. Apache Spark — унифицированный движок для крупномасштабной аналитики данных. Доступно онлайн: <https://spark.apache.org/>. (доступна 22 июля 2024 г.).

Отказ от ответственности/Примечание издателя: Заявления, мнения и данные, содержащиеся во всех публикациях, принадлежат исключительно автору (ам) и/или частника (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.