

Б.Е. Амиргалиев

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА
СОВМЕСТНОГО ПОЛЬЗОВАНИЯ
АВТОМОБИЛЕЙ: БИЗНЕС-АНАЛИЗ,
ПРОЕКТИРОВАНИЕ И ТЕХНОЛОГИИ
ИДЕНТИФИКАЦИИ ПОЛЬЗОВАТЕЛЕЙ

Монография



ДАРЫН

Баспасы

Алматы

2025

УДК 623
ББК 39.12
А 53

*Издание представлено к печати по решению Ученого совета Astana IT
University
(протокол №13 от 26 июня 2025 г.)*

Рецензенты:

Муханов С.Б., PhD, ассистент профессор Департамента интеллектуальных систем и кибербезопасности, ТОО «Astana IT University».

Бердышев А.С., д-р физ.-мат. наук, профессор, заведующий кафедрой «Математики и математического моделирования» КазНПУ им. Абая.

Мамырбаев О.Ж., PhD, профессор, ведущий научный сотрудник, заместитель генерального директора ИИВТ КН МНВО РК.

Амиргалиев Б.Е.

А53 Интеллектуальная система совместного пользования автомобилей: бизнес-анализ, проектирование и технологии идентификации пользователей: монография / Б.Е.Амиргалиев. – Алматы: Дарын, 2025. – 138 с.

ISBN 978-601-311-234-3

Монография посвящена разработке интеллектуальной системы каршеринга, включающей проектирование цифровой платформы, реализацию пиринговой бизнес-логики и создание модулей идентификации на основе методов компьютерного зрения и глубокого обучения. Особое внимание уделено применению машинного обучения в процедурах KYC, верификации личности и мониторинга поведения водителей.

Рассматриваются технологии распознавания лиц, поведенческой аналитики на основе телеметрии, а также динамическая модель максимизации прибыли для оптимального распределения ресурсов в городской мобильности.

Работа охватывает все этапы — от постановки задачи до реализации платформы и баз данных.

Монография адресована исследователям, инженерам и студентам, занимающимся вопросами цифровизации транспорта и интеллектуальных систем.

Монография подготовлена в рамках научной программы BR24992852 «Разработка интеллектуальных моделей и методов цифровой экосистемы Smart City для устойчивого развития города и повышения качества жизни горожан».

УДК 623
ББК 39.12

ISBN 978-601-311-234-3

© Амиргалиев Б.Е. 2025
© «Дарын баспасы», 2025

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	4
1 Бизнес-анализ системы совместного пользования автомобилями.....	7
1.1 Сравнительный анализ современных трендов в каршеринге	7
1.2 Обзор бизнес-моделей каршеринга.....	10
1.3 Дизайн бизнес-требований приложения по пиринговой модели.....	13
1.4 Обзор перспектив совместного пользования автомобилей как элемент совместной мобильности.....	15
2. Разработка интеллектуальной информационной системы каршеринга: модели и методы сбора, обработки и интеллектуального анализа данных.....	23
2.1 Исследование и разработка структурной модели сбора данных.....	23
2.1.1. Общая архитектура систем каршеринга.....	23
2.1.2 Структурная модель	24
2.1.3 Архитектура системы сбора данных	28
2.2 Модели и методы обработки исходных данных	31
2.2.1 Обзор технологий используемые в каршеринге	31
2.2.2 Модель идентификации водителя	38
2.2.3 Динамическая модель максимизации прибыли	48
2.3. Проектирование однорангового приложения, разработка модели и метода интеллектуального анализа данных для определения “безопасного стиля вождения”	60
2.3.1 Проектирование общей архитектуры предлагаемой системы	60
2.3.2 Проектирование однорангового приложения каршеринга	61
2.3.3 Модель определения безопасного стиля вождения	73
2.3.4 Анализ поведения водителя используя данные телематики и моделей глубокого обучения	78
3. Разработка и оптимизация алгоритмов глубокого обучения для реализации системы видеонаблюдения с функцией распознавания лиц.....	84
3.1. Методы определения людей, трекинга и распознавания лиц.....	86
3.1.1 Обнаружение людей.....	86
3.1.2. Отслеживание людей	92
3.1.3 Идентификация человека	92
3.1.4 Распознавание лиц	93
3.2 Приложения методов машинного обучения для распознавания лиц, определения объектов и их трекинга	96
3.2. Исследование и разработка структурной модели сбора и подготовки больших данных для машинного и глубокого обучения	99
3.2.1. Модель сбора и подготовки большого объема данных для обучения глубоких нейронных сетей	99
3.2.2. Предобработка данных для распознавания лиц, людей	104
3.2.3 Аугментация данных для глубокого обучения	107
3.2.4. Структурная модель системы для контроля доступа и распознавания пассажиров	109
ЗАКЛЮЧЕНИЕ	117
ПРИЛОЖЕНИЕ А	129
ПРИЛОЖЕНИЕ Б.....	135

ВВЕДЕНИЕ

Мегаполис представляет собой комплексную систему, с большим множеством различных подсистем, где процессы коммуникации не отработаны должным образом. В данном случае, важным условием является разработка инструментов для самооценки в целях достижения глобальных Целей Устойчивого Развития Организации Объединенных Наций, что соответствует инициативе «Объединения усилий в целях построения «Умных и устойчивых городов» и его ключевым показателям эффективности.

Непрерывный рост численности населения и расширение городской застройки приводят к увеличению числа личных автомобилей. Это, в свою очередь, порождает множество вызовов в области городской мобильности, включая ухудшение транспортной ситуации и рост экологических угроз. Первая проблема выражается в снижении транспортной эффективности и увеличении заторов в часы пик. Вторая — оказывает куда более серьезное влияние на качество жизни и здоровье населения.

Согласно Парижской декларации по вопросам электромобильности и изменения климата, транспортный сектор уже сегодня ответственен за 23% глобальных выбросов парниковых газов, связанных с энергопотреблением, и демонстрирует наиболее быстрые темпы роста среди всех секторов [1]. Эта доля, по прогнозам, будет только увеличиваться к 2030 году, особенно в урбанизированных зонах, где преобладает использование личных автомобилей, а такие альтернативы как пешие прогулки, велосипедный транспорт и общественный транспорт остаются на вторых ролях из-за неразвитой городской среды [2].

При этом, как отмечается в [3], большинство личных автомобилей используется менее одного часа в сутки, что говорит о крайне неэффективном использовании ресурсов. Организация экономического сотрудничества и развития (OECD) также подчёркивает: транспорт является одним из ключевых источников выбросов CO₂, и именно на него следует обратить внимание при реализации мер по снижению этих выбросов [4].

Многие города мира уже внедрили инновационные подходы к мобильности, включая сервисы аренды велосипедов, каршеринга, совместные поездки и даже пилотные проекты автономного транспорта [5]. Однако в Казахстане такие решения пока мало

распространены.

По данным OECD, около 70% всех поездок в Казахстане совершается на личных автомобилях, тогда как доля общественного транспорта составляет лишь 25–30%. Такая зависимость от личного транспорта особенно критична в крупнейших городах страны [6]. Азиатский банк развития также указывает на необходимость внедрения устойчивых транспортных решений и вовлечения частного сектора в эти процессы.

Одним из таких решений может стать развитие совместного пользования автомобилями (далее, каршеринг) — модели краткосрочной аренды автомобилей, позволяющей сократить личное владение транспортом. Исследование, проведённое в Палермо (Италия), показало, что внедрение каршеринга способствовало снижению загрязнения воздуха: выбросы PM10 сократились на 25%, а CO₂ — на 38% [2].

Идея каршеринга зародилась ещё в 1987 году в Швейцарии [7] и прошла большой путь — от аналоговых схем до современных цифровых платформ, таких как Yugo от Toyota в Дублине, где автомобили доступны по модели «оплата за использование».

Европейские города, такие как Цюрих, Вена, Берлин, Гамбург и Мюнхен, уже демонстрируют устойчивое снижение доли поездок на личных автомобилях даже при высоком уровне автомобилизации [8]. Это стало возможным благодаря развитию инфраструктуры для пешеходов, велосипедистов и общественного транспорта, а также программам поддержки совместной мобильности [9].

Помимо каршеринга, в Европе активно развиваются и другие форматы: карпулинг, райдшеринг, совместные поездки на такси и микроавтобусах [10].

Исследования показывают, что совместная мобильность приносит ощутимые экологические и социальные выгоды. В условиях растущего интереса к моделям совместного потребления (от одежды до энергии), внедрение peer-to-peer каршеринга (межпользовательская аренда автомобилей) может быть эффективным шагом в сторону устойчивой городской мобильности в Казахстане.

Однако для реализации таких решений необходимо изучить текущую ситуацию, включая риски, барьеры и уровень готовности граждан к переходу на модели совместного использования автомобилей. В Казахстане пока недостаточно исследований,

посвящённых этой теме.

В отчёте UNECE [11], посвящённом перспективам совместной мобильности в Центральной Азии, предложены 5 шагов для внедрения каршеринга и карпулинга:

1. Разработка и актуализация плана устойчивой городской мобильности (SUMP);
2. Формирование нормативной базы для реализации инициатив;
3. Создание административной процедуры выдачи разрешений;
4. Предоставление экономических стимулов для операторов;
5. Система мониторинга эффективности внедрённых мер.

В разделах 2 и 3 описывается разработанная структурная модель сбора данных: концептуальная, логическая и физическая модель. Приведена архитектура системы сбора данных из датчиков, установленных на автомобиле. Также, описаны разработанные методы обработки данных и модели, разработанные на основе них: модель идентификации водителя, динамическая модель максимизации прибыли. Дополнительно были разработаны и использованы алгоритмы машинного обучения для построения модели идентификации водителя: K-ближайших соседей, случайный лес, дерево решений, и многослойный персептрон.

1 БИЗНЕС-АНАЛИЗ СИСТЕМЫ СОВМЕСТНОГО ПОЛЬЗОВАНИЯ АВТОМОБИЛЯМИ

1.1 Сравнительный анализ современных трендов в каршеринге

Развитие автомобильной промышленности, поддерживаемое стремительным ростом населения и растущей урбанизацией ставит перед обществом новые экологические вызовы. Это особенно затрагивают жизнь в крупных городах, где высокий уровень мобильности скорее требование времени, чем выбор. В этой связи развитие экономики озабочены реализацией концепции умных городов, которая, согласно литературным источникам, включает в себя следующие элементы: умное правительство, умные люди, умная экономика, умный транспорт, окружающая среда и жизнь [12]. Тем временем, каршеринг как вид совместной мобильности набирает все большую популярность и является одним из ключевых решений для умного транспорта и, следовательно, для умных городов. По мнению консалтинговых агентств, ожидается постоянный потенциал роста совместной мобильности и каршеринг открывает новые широкие возможности для автопроизводителей, поставщиков и многих других игроков в этой сфере. Так, McKinsey and Company заявили, что к 2030 году «... 63% из тех, кто в настоящее время пользуется услугами мобильности, не связанных с такси, ожидают, что их использование «значительно» увеличится последующие два года, и даже больше (67%) заявили, что ожидают то же самое в отношении каршеринга» [13].

На сегодняшний день одной из задач развития транспортной инфраструктуры является развитие экономики совместного потребления, включающий в себя каршеринг и услуги микромобильности. Каршеринг рассматривается как потенциальный рычаг для уменьшения автомобильной зависимости и ограниченности движения, улучшения экологической среды, развитию транспортной инфраструктуры, а также способствует стимулированию устойчивого развития городов [14]. Так, например, снижение выбросов парниковых газов, уменьшение количества владельцев транспортных средств и километра пробега часто связывают с развитием услуг микромобильности, в частности каршеринга

[15-17]. В статьях [17-20] также отражено, что использование каршеринга поддерживает сдвиг к использованию мультимодального, экологически безопасного транспорта, дополняющего общественные и активные виды транспорта (езда на велосипеде, пешая ходьба).

Исследования, проведенные в направлении каршеринга, также как количество опубликованных статей за последние четыре года, более чем вдвое превысило общее количество за все предыдущие года вместе взятые [21]. Если рассматривать опубликованные статьи, их условно можно разделить на две группы: статьи касающиеся технических аспектов и моделирования [22,23] и статьи охватывающие бизнес содержание каршеринга [24]. В статье [25] использовали собственно разработанную таксономию для обзора 137 статей по двум категориям: журналы (94 статьи) и вестники (43 статьи). Большинство статей в обзоре использовались из журнала “Transportation Research Record and Transportation Research Part A-F”. В [25] описаны общие тенденции, тренды и перспективы исследований в направлении каршеринга. В частности, вопросы поведения пользователей и фактором влияющих на выбор каршеринга вместо традиционного транспорта, анализ спроса - описание методов определения спроса и предложения; оптимизация каршеринговых сервисов - проектирование сервиса, инфраструктуры и управления парком авто с целью оптимизации; а также, бизнес-модели, бизнес-разработка и экономика каршеринга.

Несмотря на то, что каршеринг приобрел большую популярность в развитых частях света, в некоторых странах по-прежнему наблюдается “непринятие”. Следовательно, понимание мотивации выбора услуг каршеринга - один из первых шагов. Таким образом, «... понимание характеристик и мотивов приверженцев и не адептов каршеринга важно как для политиков, так и для бизнеса, чтобы поддержать более широкое распространение каршеринга» [26]. Тем временем, независимо от количества владельцев личного автомобиля, все больше жителей мира начинают отдавать предпочтение каршеринговым сервисам. По данным Европейской Экономической Комиссии ООН (ЕЭК ООН) [27], «... это уже реальность в крупных городах, где из-за чрезмерной загруженности дорог, высокой стоимости парковки или их отсутствия частный автомобиль как общее явление начинает давать путь к новым формам мобильности». Сокращение выбросов

углекислого газа - одна из наиболее рациональных причин, по которой страны должны внедрять и продвигать технологии и услуги каршеринга.

Согласно данным, несмотря на экологические преимущества, некоторые муниципалитеты все еще не отдают предпочтение созданию инфраструктуры, способствующей каршерингу. Например, в Токио «... было заявлено, что каршеринг увеличивает объем моторизованного движения и вызывает заторы на дорогах, и по этим причинам есть районы, где каршеринг не одобрен муниципалитетом города» [28]. Судя по результатам этого исследования, похоже, что мотивация к выбору личного автомобиля вместо каршеринга все еще присутствует даже в таком высокотехнологичном городе, как Токио. В ходе исследования были также выявлены социологические и культурные факторы, заставляющие жителей Токио пользоваться личными авто. Таким образом, качественными показателями, определяющими предпочтение владения личным автомобилем, были «эмоциональный фактор», «фактор удобства» и выбор «личного пространства». Хотя это исследование ограничено наблюдением только за 23 случаями в Токио, оно ясно показывает, что продвижение услуг каршеринга не может быть успешным без понимания социально-экономических, культурных и ментальных аспектов, которые могут оправдать выбор того или иного типа мобильности. Таким образом, результаты показали, что сила эмоционального фактора как полезности владения автомобилем более чем в два раза превышала фактор удобства. В другом исследовании говорится, что изменение мобильности потенциальных пользователей услуг каршеринга является проблемой. Авторы утверждали, что «... одной из основных проблем остается привлечение основных потребителей к использованию услуг каршеринга и изменению их поведения в мобильности» [29]).

Несмотря на то, что рынок каршеринга в Казахстане развивается, в результате сравнительного анализа наблюдается множество ограничений. Таким образом, на внедрение и развитие каршеринга в Казахстане могут повлиять разные факторы:

- по сравнению с европейскими странами расстояния между городами в Казахстане больше, и даже если каршеринг будет развиваться, он с большей вероятностью будет происходить в крупных городах (Астана, Алматы, Шымкент);
- регулирование каршеринга нормативными документами

остаётся ограниченным, поэтому четкое понимание того, как работают поставщики услуг каршеринга не сформировано. В связи с этим некоторые данные приводятся в отчете ЕЭК ООН [27];

– по сравнению с многочисленными исследованиями, проведенными в некоторых крупнейших городах мира как Токио, Париж и др., мы можем наблюдать отсутствие эмпирических данных по Казахстану о мотивации, ограничениях и возможностях каршеринга, что создает ограничения в развитии данного вида мобильности.

1.2 Обзор бизнес-моделей каршеринга

Free floating carsharing. Free-float каршеринг - тип каршеринга, который позволяет брать автомобиль в аренду с локации, где доступен автомобиль и оставлять в любом месте, в рамках разрешенной зоны покрытия сервиса. Аренда автомобиля осуществляется через мобильное приложение, доступ к авто пользователи получают через бесключевой доступ (через bluetooth). На арендуемые авто действует система поминутной тарификации.

Одним из недостатков данного типа каршеринга является необходимость сервису иметь достаточно большой парк автомобилей, чтобы обеспечивать спрос. Данные автомобили также необходимо оснащать специальными техническими средствами (GPS-позиционирование, бесключевой доступ, GSM-связь).

К примерам компании, которые работают по бизнес-модели free floating является Zipcar (США), Enterprise Car share (США), Car2Go (США), BelkaCar (Россия), Anytime (Россия, доступен также в Казахстане). DosCar (Казахстан) является отличным примером каршеринга, работающим по данной модели.

Стационарный каршеринг. Данный тип каршеринга предполагает аренду автомобиля с фиксированной локации и возврат также в ту локацию. На автомобили действует система почасовой тарификации, иногда могут взиматься фиксированная ежегодная стоимость подписки. Примеры компании, работающих по модели стационарного каршеринга - Car City Club (Италия) [30], DosCar (Казахстан).

Пиринговая модель каршеринга. Пиринговая модель каршеринга (peer-to-peer) является разновидностью стационарного типа каршеринга, требуется взятие в аренду и возврат авто в

фиксированную локацию. Отличие от стационарного каршеринга в бизнес-модели, пиринговая модель каршеринга позволяет физическим лицам и юридическим лицам сдавать свое авто в каршеринг. Автомобиль сдается на несколько часов, обычно на сутки. Turo (США) [31], GetAround (США) [32].

Изучая бизнес-модели различных сервисов, мы пришли к выводу, что при разработке сервиса каршеринга нам необходимо руководствоваться пиринговой модели каршеринга. Учитывая преимущества и недостатки различных моделей описанных в [33], к преимуществам пиринговой модели можно отнести относительно низкую стоимость “входа в рынок”, предоставление различных вариантов авто, отсутствие необходимости содержать штат и помещении для технического обслуживания и паркинга автомобилей.

На основе канваса бизнес-модели Turo мы разработали собственный канвас бизнес-модели (Таблица 1.1).

Таблица 1.1 - Канвас бизнес-модели нашего сервиса.

Ключевые партнеры Владельцы авто Платежные системы Страховые компании Акимаг г.Астана Astana Innovations	Ключевые активности Разработка платформы Поддержка ИТ системы Поддержка пользователей Маркетинг и продвижение Привлечение владельцев авто и пользователей Правовые аспекты	Ключевые ценности Клиенты имеют безопасный и надежный способ путешествия Возможность дополнительного заработка для владельцев автомобиля, когда автомобиль простаивает	Отношение с заказчиками Маркетплейс пиринговой модели каршеринга Проверка владельцев авто и пользователей используя Know your customer (KYC) систему -> безопасность, уменьшение мошенничества Владелец авто выбирает в календаре доступное время авто Пользователь выбирает свободное время автомобиля, бронирует и вносит оплату	Сегменты заказчиков Владельцы авто Путешественники Корпоративные клиенты
	Ключевые ресурсы ИТ-система Квалифицированная команда Поддержка акимата		Каналы Мобильное приложение iOS, Android. Прямые каналы через компании, сдающие автомобиль	
Структура стоимости Покрытие ущерба авто путем страхования, ЗП работников, Поддержка ИТ инфраструктуры, Разработка продукта Маркетинг, Поддержка пользователей, Служба безопасности			Источники дохода Владельцы автомобилей могут установить свою цену Мы берем 20%.	

Если рассматривать Казахстан, то рынок каршеринга недостаточно развит по сравнению с Европой и США, из активных каршеринговых провайдеров в Казахстане присутствует российский оператор - Anytime. По сравнению с другими сервисами по аренде авто, anytime работает по модели free-floating бизнес-модели и на текущий момент представлен 240 автомобилями в Алматы. Ключевое отличие, каршеринговых сервисов от традиционных сервисов по аренде авто является наличие мобильных приложений, поддержка пользователей 24/7, у сервисов работающих по free-floating модели возможность арендовать автомобиль “без ключа” через мобильное приложение, а также возможность забирать и оставлять автомобиль в любой точке города.

Еще одной особенностью каршеринга в Казахстане является наличие решения провайдера (в нашем случае, Anytime) в ограниченной версии. Имеются ограничения как по количеству доступных автомобилей и моделей (в Казахстане представлены только 3 модели авто, в то время в России более 14), также отсутствуют дополнительные сервисы - Anytime Prime, предоставляющий автомобиль по подписке с полным обслуживанием на длительный период времени. Также, сервис концентрирован только в определенной локации (как например, anytime в Алматы), имеется возможность выезжать в туристические места, находящийся за чертой города (Капчагай, Шымбулак и др.). В то время как зарубежные аналоги предлагают большую свободу передвижения своим пользователям, предоставляя также и авто для дальних поездок (например, ZipCar в США), где клиент может начать пользование услугой в одной локации (к примеру, в Бостоне), а закончить в другой (например, Чикаго). Это демонстрирует интегрированную и слаженную организацию работы компаний, что увеличивает доверие среди пользователей сервиса, а также увеличивает возможности для мобильности в целом. Для самих же компаний это увеличение пользовательского сегмента и соответственно прибыли от предоставляемых услуг.

1.3 Дизайн бизнес-требований приложения по пиринговой модели

Есть 2 актера: Гости, которые бронируют машину, и хозяин, который предоставляет машину. На следующих диаграммах показаны варианты использования, которые может выполнять

каждый актер.

а) В данном пункте описывается сценарии использования, выполняемый гостем (Рис.1.1).




Рисунок 1.1 - Сценарии использования для гюста

б) В данном пункте описывается сценарии использования, выполняемые владельцем автомобиля (Рис.1.2)




Рисунок 1.2 - Сценарии использования для хюста (владельца автомобиля)

1.4 Обзор перспектив совместного пользования автомобилей как элемент совместной мобильности

Настоящее исследование направлено на восполнение пробела в научной литературе путём проведения обзорного опроса участников рынка каршеринга в Казахстане — как со стороны пользователей (B2C), так и компаний (B2B). Это позволит собрать практические данные, которые могут быть полезны для государственных органов при планировании и реализации инициатив в области совместной мобильности.

Фокус сделан на peer-to-peer модели, при которой пользователи оплачивают членство и получают доступ к автомобилям, принадлежащим другим частным лицам.

Раздел структурирован следующим образом: сначала описывается методология и обоснование выбранных подходов, затем представлены ограничения исследования и его результаты. Завершающие разделы посвящены обсуждению и выводам.

Методология. Данный раздел посвящен оценке рисков, связанных с использованием каршеринга. Целью исследования является проверка вероятности возникновения рисков, ранее выявленных в рамках предварительного этапа проекта. В рамках работы рассматриваются следующие три исследовательских вопроса:

- Какие риски ассоциируют с каршерингом компании и потенциальные пользователи?
- Насколько казахстанские потребители готовы к использованию каршеринга?
- Какие препятствия существуют для развития бизнеса каршеринга в Казахстане?

Для ответа на эти вопросы были проведены два взаимосвязанных исследования: (1) опрос в секторе B2B и (2) опрос в секторе B2C. В рамках исследования B2B были отобраны 9 компаний, предоставляющих услуги аренды автомобилей. Анализ данных основан на результатах онлайн-опроса и четырёх дополнительных фокус-интервью. Выбор именно компаний по аренде автомобилей объясняется тем, что в Казахстане на момент исследования функционирует лишь одна компания, предоставляющая услуги каршеринга, и данные от прокатных компаний позволяют получить достаточную информацию о вероятности рисков, поскольку их клиентская база схожа.

Данные по сектору B2B были собраны в двух городах с наибольшей степенью урбанизации — Астана и Алматы. Для сбора информации применялся смешанный метод: онлайн-опрос и фокус-интервью.

Для ответа на первый и второй исследовательские вопросы был проведён онлайн-опрос среди 121 респондента из сектора B2C различных возрастов. Анкета включала вопросы об их демографическом профиле, восприятии рисков, связанных с каршерингом, мобильном поведении и опыте использования различных форм совместной мобильности.

Несмотря на то, что статья рассматривает потенциальные риски, связанные с каршерингом, ограничением данного исследования является объём выборки в B2B-сегменте. Изначально предполагалось проведение опроса среди компаний, расположенных в Астане, однако из 20 приглашённых компаний согласие дали только 9. В связи с этим в выборку был включён также город Алматы. В результате большинство опрошенных компаний находятся в Астане, а лишь незначительное количество — в Алматы, что создало определённый территориальный дисбаланс. Для его компенсации и проверки согласованности полученных данных дополнительно были проведены интервью с 4 компаниями из Алматы.

В результате данного исследования был проведён опрос среди 9 компаний по аренде автомобилей, а также проведены интервью с представителями ещё 4 компаний. Таким образом, в общей сложности были собраны данные от 13 компаний, что составляет около 50% целевой аудитории в городе Астана и 25% — в городе Алматы.

Представленный обзор, как предполагается, может быть интересен широкому кругу заинтересованных сторон, включая представителей академической среды, сектора B2B, иностранных инвесторов, обычных граждан и других участников.

Эти ответы создали возможность оценки фактической вероятности рисков на основе реального опыта казахстанских компаний. Однако также необходимо понимать модели поведения граждан Казахстана в отношении мобильности. Как утверждают авторы, «...социально-демографические переменные являются ключевыми факторами моделей мобильности и способов передвижения и могут определять распространение услуг каршеринга среди городского населения» [34]. Поскольку модели

мобильности граждан Казахстана еще не изучены, в рамках данного исследования был проведен онлайн-опрос 121 гражданина Казахстана. Собранные данные включают геодемографические характеристики пользователей, их опыт использования услуг совместной мобильности, мотивацию к использованию различных типов мобильности и т.д.

Восприятие пользователями рисков каршеринга

Результаты опроса клиентов показывают, что большинство (59,1%) пользователей «не готовы» размещать свои автомобили для сервиса каршеринга в качестве «Хоста».

Чтобы понять, почему респонденты не были готовы размещать свои автомобили, их попросили указать причину. Из 20 ответов, поясняющих причину неготовности, 11 были связаны с «личным использованием». Это касается готовности клиентов быть единственными пользователями своих автомобилей, не делясь ими. Здесь интересно отметить, что клиенты, которые дали такой тип ответа, воспринимают свои автомобили как часть своей идентичности или стиля и не смотрят на свои автомобили только как на средство передвижения. В какой-то момент это похоже на ответы из анализа мотивации владения автомобилем в городе Токио, где готовность владеть личным транспортным средством была тесно связана с готовностью граждан иметь «личное пространство» [35]. Другим популярным ответом на вопрос о несовместном использовании личных автомобилей было «отсутствие доверия» к потенциальным клиентам с возможностью неточного использования, риском повреждения автомобиля, рисками, связанными с неправильным поведением вождения, и финансовыми рисками, связанными с неправильным использованием автомобиля.

Хотя эти ответы явно не повторяют риски, перечисленные в первоначальном описании оценки рисков, они согласуются с результатами опроса компании. Таким образом, такие риски, как «агрессивное вождение», «нарушение правил дорожного движения», «кража автозапчастей» и «мошенничество», могут быть связаны с ответами клиентов о недоверии третьим лицам в использовании их автомобилей из-за возможности неаккуратного использования, риска повреждения автомобиля, рисков, связанных с неправильным поведением вождения, финансовых рисков, связанных с неправильным исполнением автомобиля. Таким образом, если смотреть с обеих сторон (компании и клиента),

граждане Казахстана сталкиваются с несколькими барьерами, прежде чем они смогут разместить свои автомобили на платформах каршеринга. Риски, которые упомянуты выше, связаны с поведением вождения и менталитетом потенциальных клиентов каршеринга, и, следовательно, должны быть учтены при проектировании системы.

Чтобы получить представление о том, как эти риски могут быть устранены в системе, клиентов, которые были готовы разместить свои автомобили для сервисов каршеринга, попросили указать условия, на которых они согласились бы разместить свои автомобили. 50% (5 из 10) ответов на этот вопрос указали на явную готовность разместить личные автомобили для сервисов каршеринга, «если финансовая выгода будет достаточной» от этого. В исследовании, проведенном с целью изучения детерминант намерения потребителя использовать сервисы совместных поездок, были обнаружены схожие результаты, мотивирующие пользователей на сервисы совместных поездок. Таким образом, авторы заявили, что такие факторы, как «...удовлетворенность, воспринимаемая полезность, экономические выгоды, экологическая осведомленность и стимулы платформы» являются факторами, определяющими мотивацию пользователей к использованию сервисов совместной мобильности [36]. Вторым популярным ответом было рассмотрение важности «опыта водителя» при совместном использовании автомобиля. Из общего обзора ответов можно сделать вывод, что хозяева, которые готовы поделиться своими автомобилями, указывают на необходимость оценки потенциальных пользователей на основе их истории вождения, страховых рейтингов и опыта вождения, чтобы снизить риски агрессивного вождения, нарушения правил дорожного движения и других. Также указано, что пользователи более готовы размещать свои автомобили, если соглашение, в котором указаны все вышеупомянутые положения и условия, может быть подписано до того, как потенциальным пользователям системы может быть предоставлен автомобиль. Это на самом деле может помочь повысить ответственность потенциального пользователя за его поведение вождения и общее использование автомобиля.

Геодемографические характеристики

Географическое распределение этого опроса можно считать ограничением, поскольку не все регионы представлены среди

участников. Так, около 50% опрошенных участников являются жителями Астаны (61). Остальные участники равномерно распределены в Алматы (26) и Таразе (26). Было мало ответов из других городов Казахстана, таких как Уральск, Шымкент и Атырау. Чтобы иметь лучшее представление об опрошенных пользователях, в этом разделе будут представлены некоторые основные характеристики участников опроса клиентов. Большинство опрошенных участников были молодыми водителями (45,8%). Участники в возрастных категориях «25-34» и «35-44» были распределены равномерно — 22,5% и 20,8% соответственно. Было опрошено меньше представителей пожилых граждан. Так, респонденты в возрастных категориях «45-54» (7,5%), «64 и старше» (2,5%) и «55-63» (0,8%) составили наименьшее количество опрошенных участников. Это можно объяснить общей активностью молодого поколения в участии в опросах, а также их открытостью к изменениям. Как утверждают авторы, «...молодые люди более охотно принимают эти новые возможности мобильности» [37]. Это было подтверждено в другом европейском исследовании, где возраст был отрицательным показателем мотивации пользователей к совместному использованию автомобилей, указывая на то, что «...молодые поколения более охотно используют совместное использование электромобилей» [30].

Хотя распределение по возрасту в этом опросе было неравномерным, гендерное распределение было более равномерным. Таким образом, 58,3% респондентов были мужчинами, а 41,7% — женщинами, что помогло избежать гендерно-предвзятых ответов. Важно отметить, что семейное положение респондентов опроса было практически одинаковым. Таким образом, половина (50,4%) респондентов были «холостыми», а остальные 45,4% были «замужем». Лишь незначительное число респондентов были «разведены» (3,4%) или «потеряли партнера (вдовы/вдовцы)» (0,8%).

При рассмотрении моделей мобильности респондентов также важно было обратить внимание на их общий опыт вождения. Так, из 121 опрошенного участника 67,5% ответили о наличии водительских прав, из которых 45,6% имели стаж вождения «более 5 лет», «от 2 до 5 лет» (22,8%), «менее 2 лет» (22,8%) и только 8,9% ответили об отсутствии опыта вождения. 53,2% этих участников также ответили о «владении личным автомобилем», в то время как другие 46,8% ответили об отсутствии такового.

Тем респондентам, у которых не было личного автомобиля, было предложено указать частоту использования следующих вариантов мобильности: общественный транспорт, службы такси (Яндекс, Uber, InDriver) или «служебный автомобиль». Самым непопулярным выбором для респондентов было использование «служебного автомобиля». Участники в равной степени ответили на использование услуг такси (Яндекс, Uber, InDriver) со «средней» и «высокой» частотой. Те, кто не водит личный автомобиль, пользуются общественным транспортом со «средней» частотой и редко пользуются общественным транспортом для того, чтобы добраться до места назначения.

На вопрос о том, почему те, у кого нет личного автомобиля, предпочитают это делать, большинство респондентов (17 ответов) согласилось с тем, что «покупка автомобиля — это дорого», «эффективность времени общественного транспорта с учетом заданной полосы движения» (16 ответов), «дешевые цены на общественный транспорт» (15), «высокие расходы на бензин, техническое обслуживание, страховку и т. д. в случае владения личным автомобилем» (15). По сравнению с этими причинами, получившими одинаково большое количество ответов, «проблемы с парковочным местом» указали только 5 респондентов.

В то же время, несмотря на то, что многие респонденты, выбирающие общественный транспорт, указывают на неудобства общественного транспорта по ряду причин. 75% респондентов указали на «слишком многолюдный общественный транспорт», «неудобные поездки». Такое же количество пользователей (по 34,5%) указали на то, что «в салонах общественного транспорта обычно душно и грязно», и что у них, как правило, «нерегулярное расписание». Некоторые респонденты не любили пользоваться общественным транспортом, потому что «рядом не было автобусных остановок». Были и другие ответы о том, что «услуги такси — более быстрое решение», «долгое время ожидания автобусов», на которые было получено мало ответов.

Знакомство пользователей с услугами каршеринга

Пользователям был задан вопрос об их знакомстве с услугами каршеринга, на который 90% ответили положительно. Только 10% респондентов не были знакомы с услугами каршеринга. На вопрос об использовании таких сервисов (каршеринг, прокат автомобилей, велосипед, скутер и т.д.) ответы немного различались

между теми, кто пользовался вышеупомянутыми системами (54%), и 44%, кто не пользовался. Было мало ответов о том, что они не уверены в этом вопросе (2,6%).

Среди тех, кто пользуется услугами совместного пользования мобильностью, наиболее популярным типом был «кикшеринг» (11 ответов), «прокат велосипедов, таких как Astana bike, Almaty bike» (7 ответов), «каршеринг» (6 ответов), «проезжающие мимо автомобили» (1 ответ). Их также попросили указать на любые проблемы при использовании определенного типа услуг совместного пользования.

Проблемы, связанные с кикшерингом, включают «нефиксированные цены», «необходимость загрузки приложения», «быстрый расход батареи и высокая цена». Проблемы, связанные с совместным использованием автомобилей, включают «плохое техническое состояние автомобилей», «ограниченное количество парковочных мест», «отсутствие гибкости в выборе времени, за опоздание взимается плата», «автомобили совместного использования автомобилей не всегда чистые», «процесс проверки автомобиля перед поездкой занимает слишком много времени», «ограниченное количество автомобилей».

Решения, предложенные пользователями, включают «снижение цен», «увеличение контроля за автомобилями», «включение альтернативных видов транспорта», «развитие инфраструктуры».

На вопрос о готовности пользователей размещать свои личные автомобили для совместного использования 59,1% были не готовы, 34,6% были готовы и 4,5% были нейтральны. Можно предположить, что при преодолении барьеров, описанных в «восприятии пользователями рисков совместного использования автомобилей», количество положительных ответов может быть увеличено. Аналогичное исследование в Сан-Франциско показало, что «...примерно 25% опрошенных владельцев автомобилей были бы готовы поделиться своими личными транспортными средствами через пиринговое каршеринговое обслуживание, при этом основными сдерживающими факторами были бы вопросы ответственности и доверия» [38]. Это интересно совпадает с ответами граждан Казахстана, где «недоверие» своих автомобилей другим было одним из факторов, мешавших им размещать свои автомобили.

Использование систем онлайн-платежей

Чтобы получить информацию о том, какие платежные системы знакомы пользователям, их попросили сообщить о частоте регистрации своих карт в онлайн-сервисах. На что 52% пользователей ответили, что «иногда» регистрируют свои карты, 39% сказали, что «часто» регистрируют свои карты, а остальные 9% сообщили, что «всегда» регистрируют свои карты в различных системах онлайн-платежей. Что касается систем распознавания лиц, то 80% респондентов использовали системы цифровой авторизации (сервисы Digital Face ID или Kaspi), а еще 20% ответили, что не используют их. Большинство участников также ответили о своей готовности использовать сервисы каршеринга (49,4%), некоторые из них показали возможное использование таких сервисов (35,8%), очень небольшое количество пользователей указали, что они могли бы использовать такие системы во время путешествий (1,2%), а другие четко указали, что «не будут использовать» (12,3%) или «скорее не будут использовать» (1,2%).

В результате данного исследования был выявлен обзор потенциальных рисков для системы совместного пользования автомобилями по принципу «равный-равному» и оценена их вероятность. Как и предполагалось, обычная модель совместного пользования автомобилями по принципу «равный-равному», реализованная в других западных сервисах (Zip Car, Turo или других), не может быть применима к Казахстану из-за высокой вероятности агрессивного вождения, нарушения правил дорожного движения и других важных рисков, обсуждаемых в данном исследовании. Как поведение за рулем, так и ментальное восприятие мобильности у граждан Казахстана отличается. Некоторые пользователи даже считают автомобили частью своей личности, в то время как другие не доверяют делиться своими автомобилями с другими, опасаясь финансовых потерь. Следовательно, для тех предприятий, которые хотят выйти на казахстанский рынок совместного пользования автомобилями, очень важно учитывать обсуждаемые особенности при проектировании своих систем. Как было предложено потенциальными клиентами, хороший страховой план, покрывающий все вышеупомянутые риски, разработка системы таким образом, чтобы она могла проверять потенциальных пользователей на предмет их истории вождения, рейтинга и поведения, может помочь преодолеть трудности.

2. РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ ИНФОРМАЦИОННОЙ СИСТЕМЫ КАРШЕРИНГА: МОДЕЛИ И МЕТОДЫ СБОРА, ОБРАБОТКИ И ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

2.1 Исследование и разработка структурной модели сбора данных

2.1.1. Общая архитектура систем каршеринга

На следующей диаграмме (Рис.2.1) показана конструкция системы. Основные действующие лица, такие как Заказчик, Персонал, Хост, включены в архитектуру проектирования системы. Также внутренний сервер, база данных, балансировщик нагрузки можно рассматривать как часть дизайна системы. Сервер машинного обучения (ML) и API промежуточного программного обеспечения, которые соединяют внутренний сервер с сервером ML, также являются важной частью системы.




Рисунок 2.1 - Дизайн системной архитектуры

При запуске одноранговой системы совместного использования автомобилей может возникнуть широкий спектр рисков. Мы проиллюстрировали широко распространенные случаи в следующей таблице. Вы можете видеть риски, частоту рисков, стоимость рисков, источник рисков, сценарии, которые обычно приводят к рискам, и соответствующие им решения (Приложение А).

2.1.2 Структурная модель

Концептуальная модель базы данных представляет собой не визуальную диаграмму, созданную в традиционной нотации, которая показывает связь между элементами и их ожидаемыми результатами. Чтобы генерировать точные данные и преобразовывать их, скажем, в реляционную базу данных, создается концептуальная модель. Концептуальная модель позволяет легко отслеживать связь между элементами, как показано на Рисунке 2.2.




Рисунок 2.2 - Концептуальная модель

Внутренняя система проверяет правильность заполнения новых пользователей, а затем создает профили для хоста и для клиента. Таким образом, создаются первые три сущности и связи между ними. После этого, заполнив данные о машине, хост добавляет свою машину. Приложение показывает данные машины с фотографиями и информацией клиенту. После этого создается еще одна сущность-машина и связь, которая показывает им, что клиент может выбрать автомобиль. Также, после этого клиент

выбирает вид страхования и предоставляет реквизиты для создания договора. Страхование — это отдельная организация, которая описана в новом контракте. С помощью договора записываются все детали об аренде автомобиля, после чего хозяин инициализирует и подписывает. После того, как хост подписывает клиент, клиент привязывается к контракту. Контракт имеет реквизиты сторон (клиент, хост), дополнительный полис страхования, ссылку на чек по оплате.

Логическая модель (Рис.2.3) изображает данные предметной области как набор информационных элементов со связями между ними. Эта модель отображает информацию, которая будет сохранена в базе данных. Существует два метода построения модели данных. В первом методе сначала определяются основные задачи, для которых разрабатывается база данных, а затем требования к данным для этих задач. Вторая стратегия сразу устанавливает типичные элементы в предметной области. Наиболее логичное сочетание этих двух методов. Это связано с тем, что в большинстве случаев нет детального знания всех заданий с самого начала. Внедрение такой технологии оправдано тем более, что гибкие методы построения реляционной базы данных в Access позволяют вносить изменения в базу данных и корректировать ее структуру на любом этапе разработки, не ставя под угрозу введенные ранее данные.




Рисунок 2.3 - Логическая модель

Для начала, используя концептуальную модель данных, мы обозначили сущности. После этого мы добавили атрибуты к каждой сущности. Для каждого атрибута был задан тип данных. У хозяина и клиента будет свой адрес электронной почты, пароль, имя, город, дата рождения и водительские права, а также фотографии. Для автомобиля мы добавили модель, год выпуска, пробег

автомобиля, паспорт, цвет автомобиля и стоимость аренды. Для одной поездки водитель может выбрать несколько автомобилей, но в автомобиле может быть только один водитель. У каждой машины есть один хост. И у машины одна марка. Каждая поездка создает один контракт, содержащий только одну квитанцию и информацию о страховании, которую выбирает клиент. При подписании контракта данные о дате сохраняются в таблице наличия автомобиля. А данные о поездках находятся в таблице поездок. После каждой поездки автомобилю и хозяину присваивается рейтинг, который сохраняется в таблице отзывов об автомобиле с атрибутами рейтинг и комментарий.

Физическая модель данных содержит все таблицы, столбцы, взаимосвязи и характеристики базы данных, необходимые для развертывания физической базы данных (Рис.2.4). Состав таблицы базы данных определяется на этапе проектирования физической базы данных. Важно составить таблицу спецификаций для каждого поля таблицы, включая используемый тип данных и, возможно, размер поля (для текстовых полей - количество символов). Это необходимо для предотвращения неопределенных значений для первичных ключей.




Рисунок 2.4 - Физическая модель

Используя предыдущие две модели данных, мы создали физическую модель базы данных (Рис.2.5). На этом шаге мы добавили идентификатор к каждому объекту. Для начала мы создали одну таблицу для пользователей, а для тех пользователей, у которых есть машина, мы создали таблицу хоста. Мы соединили таблицу хостов с таблицей машин с отношением «один ко многим», поскольку у машины может быть только один владелец, а у пользователя может быть несколько машин. Создавая договор, мы создаем счет-фактуру, в котором указана полная сумма за аренду автомобиля и стоимость страховки. Счет можно оплатить наличными или онлайн. Одна страховка имеет один чек и один вид страхования. Каждая поездка содержит информацию о ее местоположении.




Рисунок 2.5 - Модель БД (NoSQL)

2.1.3 Архитектура системы сбора данных

В последнее время можно заметить, что разрабатываются сервисы совместного использования авто. Основными бенефициарами данных решений являются частные лица, компании и общественные институты. В зависимости от группы клиентов они и думают по-разному, каждый ищет удобный и эффективный способ использования автомобиля. Основными причинами почему они пользуются сервисами совместного потребления являются оптимизация собственного парка автомобилей, удобство, возможность заказа авто при срочной необходимости, обеспечение

автомобилями командированных сотрудников, краткосрочные путешествия и другие. В подобных сервисах страхование автомобиля, замена колес, обслуживание, мойка авто уже включена в стоимость, соответственно клиенты меньше об этом задумываются.

Для предоставления сервисов совместного потребления - каршеринга важно иметь возможность удаленного открытия и закрытия дверей. Данная функция требует использования аппаратного обеспечения, прошивки и программного обеспечения. Трекер Teltonika FMB130 в связке с CAN-Control адаптером позволяет подключиться к CAN шине, считывать более 300 параметров, контролирует центральный замок, открытие окон, включение и выключение фар. Также, по представленной общей архитектуре (Рис.2.6) данное подключение позволяет контролировать статус открытия дверей, положение парковочного ручника, статус фар. Данные, получаемые с авто, могут включать обороты двигателя, скорость движения транспортного средства, информацию об уровне топлива и другие важные параметры в реальном времени. Подобные трекеры, FMB130 и другие используемые в проекте имеют слот для сим-карты, подключаются к сотовым вышкам. Данные, собранные из трекера отправляются через GPRS сети на сервера и далее на платформе (на рисунке 2.6 - Tracking platform) мы отображаем полученные данные.




Рисунок 2.6 - Общая архитектура сбора данных

Для реализации сервиса каршеринга необходимо иметь информацию о расположении (GPS локация) автомобиля в реальном времени, данные акселерометра для считывания стиля вождения, другие параметры, касающиеся самого процесса управления автопарком. Поэтому, в отдельности от самого сервиса каршеринга был разработан сервис по управлению парком автомобилей. Планируется разработать полноценный дашборд, показывающий всю необходимую информацию для клиентов, таким образом клиенты имеют возможность отслеживать положение автомобилей в реальном времени, а при наличии трекеров подключенных к CAN-шине удаленно отключать двигатель, либо открывать-закрывать двери.

На рисунке 2.7 представлена архитектура сбора данных. Как можно заметить, основным узлом для сбора данных является GPS-трекер, подключенный к диагностическому OBD разъему, а в некоторых случаях напрямую к CAN-шине. Далее, данные передаются на сервер flespi. Flespi служит бэкенд платформой, разработанной для быстрого подключения любых типов устройств к телематическим системам и интеграции данных в различные программные продукты посредством REST API. Бэкенд flespi работает на основе MQTT брокера, который отвечает за обмен сообщениями (данными) между бэкенд и веб-приложением. Постоянные данные (более 40 параметров автомобиля) веб-приложение хранит в базе данных. Docker отвечает за автоматическое развертывание и управление веб-приложениях.




Рисунок 2.7 - Общая архитектура сбора данных

Трекеры собирают данные с OBD-II порта, GPS-датчика и акселерометра. Данные пакуются в пакеты и собираются в памяти устройства. Затем, при накоплениях N пакетов (это свойство может быть настроено) пакеты зашифровываются в сообщение (тип зашифровки зависит от производителя трекера, Teltonika-koдек8), и отправляются на сервер.

Для получения данных на сервисе создаются каналы, которые принимают данные с трекеров. Канал — это сервер, который дешифрует сообщения и хранит их. Все трекеры отправляют данные на один сервер, и чтобы различать их на Flespi создаются девайсы. Девайс — это инстанция, которая хранит IMEI трекера (для идентификации пакетов), тип трекера (чтобы понимать какие данные трекер отправляет, потому что зависимости от типа трекера данные могут различаться), и разные конфигурации для хранения данных. Во вкладке девайсов можно посмотреть местоположение девайсов, телеметрию и логи, так же можно настроить девайс, отправить на него команду и посмотреть обработанные калькулятором данные. Калькулятор — это инстанция с алгоритмом для обработки данных. Пример, алгоритм для детекций дозаправки: в калькуляторе прописывается алгоритм для детекций увеличения количества топлива, даты и количества залитого топлива. Данные можно переслать через стримы на другие сервера или приложения.

Сервер получает данные с Flespi затем данные записываются в БД mongo-db, так же сервер может выгрузить в виде CSV файла.

2.2 Модели и методы обработки исходных данных

2.2.1 Обзор технологии используемые в каршеринге

Существуют разные способы применения глубокого и машинного обучения в системах каршеринга. Основными точками соприкосновения в исследованиях являются:

- Авторизация пользователя;
- Идентификация водителя;
- Прогнозирование транспортных потоков или управление спросом;
- Балансировка автомобиля;
- Аналитика вождения;

– Динамическая модель формирования цены и получения прибыли.

С точки зрения пользователя сервиса, для предотвращения несанкционированного доступа к транспортным средствам могут применяться механизмы распознавания лиц и защиты от спуфинга. В статьях [39,40] обсуждается использование методов глубокого обучения для обнаружения спуфинга в мобильных сервисах каршеринга. В обеих статьях используются архитектуры на основе CNN, такие как ResNet и EfficientNet. Но для таких механизмов авторизации можно применить любую современную антиспуфинг-архитектуру для мобильных систем без существенных изменений.

Методы идентификации водителя предложены в работах [39-42], в которых обсуждается архитектура систем идентификации водителей автомобилей на основе пошаговых нечетких деревьев решений, в задачах классификации рассматриваются алгоритмы машинного обучения: Decision Tree, Random Forest, Extra Trees, KNN, SVM, Повышение градиента, AdaBoost на основе дерева решений и многослойные перцептроны (MLP). В [40] для выполнения задачи идентификации водителя используют точность классификации SVM поверх полученных вложений водителей. Авторы [42] предлагают подход, основанный на ненавязчивой информации из сигналов поведения при вождении и сети экстремальной обучающей машины (ELM). В работе [43] авторы проводят крупномасштабный анализ существующих механизмов и наборов данных, и в результате, используя Security Dataset от KIA, UAH-DriveSet и HciLab Dataset, предлагают систему, состоящую из различных модулей (Рис.2.8) для предварительной и последующей обработки данных и классификации. используя KNN, случайный лес, деревья решений, повышение градиента. На следующем рисунке показана предлагаемая архитектура подхода:





Рисунок 2.8 - Архитектура сбора данных и фреймворк идентификации водителя

Прогнозирование потока (управление спросом, ребалансировка в часы пик) направлено на решение задачи прогнозирования спроса в каком-либо регионе на основе нескольких факторов, таких как время суток, данные о траектории движения транспорта, данные журнала пользовательских приложений, данные заказов, данные станций, пользовательские данные. характеристические данные и т. д. В работах [44,45,46] используются алгоритмы машинного обучения и глубокого обучения для прогнозирования пространственных и временных отношений. В статье [46] исследователи предлагают модель сверточной последовательности с несколькими графами (AMGC-Seq2Seq), которая представляет собой новую модель глубокого обучения для многоэтапного прогнозирования потока. В документе [47] обсуждается использование структуры долговременной кратковременной

памяти (LSTM) для прогнозирования краткосрочного использования транспортных средств в будущем путем анализа операций посадки и высадки в системе совместного использования автомобилей на станциях, фиксируя рабочие характеристики служба каршеринга и поведение при использовании транспортных средств с временной точки зрения. В большинстве сервисов каршеринга доступны данные о траектории движения и другие данные для прогнозирования спроса в режиме реального времени. Основываясь на прогнозе спроса на возврат, реакция на релокацию может быть более разумной. Данные из нескольких источников включают данные о траектории, данные журнала пользовательских приложений, данные о заказах, данные о станциях и данные о характеристиках пользователя. На основе этих данных была использована модель прогнозирования спроса на возврат, чтобы предсказать, вернет ли пользователь транспортное средство через 15 минут в режиме реального времени, а модель прогнозирования станции назначения была применена для прогнозирования того, на какой станции пользователь припаркуется. В [48] авторы предлагают новую систему перемещения транспортных средств с трехкратным улучшением: (i) предварительная обработка данных, (ii) прогнозирование спроса и (iii) оптимизация перемещения. Предварительная обработка данных включает (i) предварительную обработку данных, (ii) прогнозирование спроса и (iii) оптимизацию перемещения для автоматического удаления ложных запросов, вызванных сбоями поиска и ошибками приложений. Затем реальный спрос прогнозируется с использованием подхода глубокого обучения, двунаправленного закрытого рекуррентного блока (GRU). Наконец, алгоритм «Минимальная стоимость — максимальный поток» используется для максимизации прогнозируемого спроса при минимизации количества перемещений. Кроме того, система развернута в реальном варианте использования под названием «CU Toyota На:мо», который представляет собой систему совместного использования автомобилей в университете Чулалонгкорн. Точная оценка спроса на аренду и возврат на станциях каршеринга для поддержки перемещения транспортных средств имеет важное значение, поэтому [49] предлагает метод краткосрочного прогнозирования спроса на уровне станции, названный гибридной нейронной сетью на основе встраивания станций (SEHNN), интегрированной с помощью вариационного графа энкодер (VGAE) и сеть с долговременной

кратковременной памятью (LSTM). Модуль VGAE берет на себя функции извлечения и внедрения характеристик станций, в то время как модуль LSTM фиксирует регулярность временных рядов и прогнозирует спрос на уровне станций. Результаты реальных данных Ланьчжоу, Китай, показывают, что по сравнению с ElasticNet, ARIMA, LSTM и ConvLSTM средняя абсолютная ошибка предложенной модели, ориентированной на почасовое прогнозирование спроса, снижается на 56,5%, 47,2%, 38,7% и 38,5% соответственно, а также превосходит некоторые широко используемые модели среди различных интервалов и масштабов, включая основные станции и подмножество системы каршеринга. В [50] для прогнозирования времени дожития (задача прогнозирования времени до посадки автомобилей общего пользования) сформулирован двухэтапный подход: на верхнем уровне используется классификационная модель для классификации автомобилей на основе длительности вакантного времени и, на нижнем уровне моделирование времени до события применяется к каждому классу с использованием независимых моделей анализа выживания. Эмпирические результаты с использованием данных из Копенгагена демонстрируют, что модель DeepSurv обеспечивает более сильное соответствие по сравнению с моделью пропорциональных рисков Кокса (СРН).

В статье [51] метаэвристика используется для определения оптимальных местоположений транспортных средств и обсуждения результирующего потенциального влияния на доступность из определенных точек сети, сети в целом, а также потенциала мультимодальных поездок. В [52] авторы предлагают новый метод вознаграждения под названием «Двойной бонус P (Picking & Parking)» (DPB). Исследовательская проблема смоделирована как проблема Марковского процесса принятия решений (MDP), и авторы представляют Градиент глубокой детерминированной политики, современную структуру обучения с подкреплением для поиска решения. Результаты показывают, что механизм вознаграждения, воплощенный в методе DPB, может управлять поведением пользователей за счет ценового рычага, повышать привязанность пользователей и развивать привычки пользователей, тем самым увеличивая долгосрочную прибыль поставщика услуг. В статье [53] представлены различные модели машинного обучения, такие как векторная авторегрессия (VAR), опорная векторная регрессия (SVR), экстремальное повышение градиента (XGBoost),

К-ближайшие соседи (kNN) и модели глубокого обучения, в частности, долговременная кратковременная память (LSTM), рекуррентный блок с вентиляцией (GRU), сверточная нейронная сеть (CNN), CNN-LSTM и многослойный персептрон (MLP) были выполнены для различных типов функций. В результате сравнения авторы отмечают, что производительность CNN-LSTM показывает лучшие результаты среди других. В работе [54] авторы предлагают децентрализованный подход, основанный на обучении с подкреплением, к перемещению транспортных средств, а также к назначению запросов на поездку в общих системах мобильности по требованию. Каждое транспортное средство самостоятельно изучает свое поведение, которое включает в себя как перебалансировку, так и выбор запросов для обслуживания, исходя из его текущего локального и наблюдаемого исторического спроса. Подход был оценен с использованием данных об использовании такси в Нью-Йорке, сначала обслуживая один запрос транспортным средством за раз, а затем внедряя совместное использование поездок, чтобы оценить его влияние на изученное поведение перебалансировки и назначения.

Авторы [55-64] предлагают механизмы для классификации, оценки и прогнозирования вождения и поведения водителей на основе сенсорных данных. В статьях [56,57] авторы используют механизмы обнаружения событий на основе нечеткой логики для определения поведения водителя. В статье [55] было предложено более продвинутое решение на основе нейронных сетей, которое продвигает каршеринг по репутации водителя. Нейронные сети использовались для определения привычек водителей в использовании автомобилей для совместного использования. В статье [58] обсуждается использование системы для оценки оставшегося заряда электромобиля с учетом поведения вождения, измеренного с помощью смартфона. Для этого в первую очередь сравнивались данные, измеренные смартфоном и бортовой аппаратурой, чтобы продемонстрировать эквивалентность обоих источников и достаточную точность первого. Полученные профили вождения затем использовались для оценки ожидаемого расхода заряда батареи электромобилем с использованием нейронной сети для представления модели, которая использует в качестве входных данных информацию, полученную от смартфона, такую как скорость, ускорение и рывок. Система была протестирована на 10 водителях с возможностью прогнозирования ожидаемого расхода

заряда батареи выше 95%. Авторы [59] вводят два вида методов машинного обучения для оценки эффективности использования топлива при вождении с использованием натуралистичных данных о вождении. На первом этапе алгоритм неконтролируемой спектральной кластеризации использовался для изучения макроскопической взаимосвязи между поведением вождения и расходом топлива с использованием данных, собранных в процессе естественного вождения. На втором этапе динамическая информация из среды вождения и данные о естественном вождении интегрируются для создания модели взаимосвязи между различными режимами вождения и соответствующими характеристиками расхода топлива. Факторы динамической среды кодируются в поддающуюся обработке цифровую форму с использованием метода обнаружения объектов на основе глубокого обучения, так что данные об окружающей среде могут быть связаны с данными рабочего сигнала транспортного средства для предоставления обучающих данных для сети глубокого обучения. Данные обучения помечены в соответствии с распределением характеристик расхода топлива, которое получено из данных сегмента дороги и исторических данных о вождении. Эта модель, основанная на глубоком обучении, использовалась в качестве предиктора расхода топлива, связанного с различным поведением вождения. В [62] авторы классифицируют данные шины CAN транспортного средства по основным сигналам датчиков, таким как скорость, тормоз, угол поворота рулевого колеса и дроссельная заслонка, которые играют первостепенную роль в определении поведения при вождении. В частности, их подход начинается с двух методов извлечения признаков: ручной выбор признаков (HFS) и автоматический выбор признаков (AFS). Наш автоматизированный метод основан на подходе кодовой книги, который извлекает функции на основе гистограмм, характеризующие форму сигналов. Поскольку некоторые данные сигнала ведут себя очень похоже, но с разной семантикой, для получения лучшего результата был применен не только классификатор «один против одного», но и алгоритм классификации с несколькими классами. В статье [63] предлагается методология, основанная на методах машинного обучения, направленная на распознавание безопасного и небезопасного поведения при вождении с помощью данных бортовых датчиков. Исходя из этих сигналов, вычисляется набор описательных признаков, способных точно описать поведение водителя.

Два разных инструмента классификации, а именно, машины опорных векторов и нейронные сети с прямой связью, были обучены и протестированы на общедоступном наборе данных, содержащем более 26 часов общего времени вождения. Результаты классификации сообщают о средней точности выше 90% для обоих классификаторов, а тест Макнемара не показывает разницы в производительности между моделями на уровне значимости 0,05, демонстрируя конкретную возможность выявления небезопасного вождения с использованием данных автомобильных датчиков.

2.2.2 Модель идентификации водителя

Существуют десятки наборов данных для изучения поведения водителей управляющих автомобилем (таблица 1.2), но не все из них выложены в открытый доступ. Поэтому для проверки гипотез и тестовых данных были исследованы следующие наборы данных, которые можно загрузить с разрешения авторов:

1. Security dataset - Byung Il Kwak, Jiyoung Woo and Huy Kang Kim, “Know Your Master: Driver Profiling-based Anti-theft Method”, PST (Privacy, Security and Trust) 2016 [65]
2. E. Romera, L.M. Bergasa and R. Arroyo, “Need Data for Driving Behavior Analysis? Presenting the Public UAH-DriveSet”, IEEE International Conference on Intelligent Transportation Systems (ITSC), pp. 387-392, Rio de Janeiro (Brazil), November 2016 [66]
3. Stefan Schneegass, Bastian Pfleging, Nora Broy, Albrecht Schmidt, and Frederik Heinrich. 2013. A data set of real worlds driving to assess driver workload. In Proceedings of the 5th International Conference on Automotive User Interfaces and Interactive Vehicular Applications (AutomotiveUI '13). ACM, New York, NY, USA, 150-157. DOI=10.1145/2516540.2516561 [67]

Таблица 1.2 - Обзор наборов данных находящихся в свободном доступе

Наборы данных	Типы сенсоров	Собранные признаки
Security dataset	CAN шина через OBD-II	Долгосрочная топливная коррекция банк 1, температура трансмиссионного масла, момент трения, давление воздуха на впуске, максимальный крутящий момент двигателя, температура охлаждающей жидкости двигателя, давление в главном цилиндре, значение педали акселератора, сигнал положения дроссельной заслонки, абсолютное положение дроссельной заслонки, крутящий момент двигателя, включение воздушного компрессора, крутящий момент двигателя после коррекции , скорость разгона - боковая, скорость разгона - продольная, крутящий момент на рулевом колесе, крутящий момент на маховике, текущее опережение зажигания, скорость вращения колеса (LF, RF, LR, RR), частота вращения двигателя, скорость автомобиля, скорость вращения руля, заданная скорость холостого хода двигателя, текущая передача, индикация выключателя тормоза, выбор передачи, работа сцепления, требуемое увеличение оборотов двигателя
UAH-DriveSet	Приложение для оценки качества вождения "Drive-Safe", сенсоры мобильного телефона (gyro, accelerometer, GPS)	GPS: timestamp, скорость, координаты долготы и широты, высота, вертикальная точность, горизонтальная точность, курс, дифкурс (изменение курса) Акселерометр: отметка времени, логическое значение активации системы, ускорение по X, ускорение по Y, ускорение по Z, ускорение по X отфильтровано по KF, ускорение по Y отфильтровано по KF, ускорение по Z отфильтровано по KF, roll, pitch, yaw
HciLab dataset		- Сенсоры мобильного телефона: GPS, brightness, acceleration - ECG (heart-rate) - Body temperature sensor

По описанию задачи мы должны использовать датчики, которые предустановлены в автомобиле, поэтому наиболее распространенным решением этой задачи будет использование набора

данных Security Dataset (KIA). Два других набора данных требуют установки дополнительных датчиков (датчиков мобильного телефона, ЭКГ, датчика температуры и т. д.).




Рисунок 2.9 - Путь тестовых заездов общей протяженностью 40 км

Были проведены тесты на первом наборе данных (Рис.2.9), но результаты не были похожи на то, что было описано в оригинальных статьях. Причин может быть 2:

1. Для обучения алгоритмов и моделей использовались другие параметры.

2. В наборе данных Security Dataset (KIA), предоставленном исследователями из [27], не было столбца «Температура трансмиссионного масла». По мнению авторов упомянутой статьи, на результаты идентификации сильно влияют два ключевых параметра — «Долговременная корректировка топлива, ряд 1», «Температура трансмиссионного масла».

Проверка гипотез аналогичных работ. Чтобы проверить первый вопрос, мы попытались обучить алгоритмы и модели (Рис.2.10), используя разные настройки (например, для KNN, меняя количество соседей, используя случайное состояние и т. д.).

Результаты для KNN:

‘Mean Training Accuracy’: 79.56499682809476,
‘Mean Training F1 Score’: 0.7956499682809476,
‘Mean Training Precision’: 0.7956499682809476,
‘Mean Training Recall’: 0.7956499682809476,
‘Mean Validation Accuracy’: 73.99237825953712,
‘Mean Validation F1 Score’: 0.7399237825953712,
‘Mean Validation Precision’: 0.7399237825953712,
‘Mean Validation Recall’: 0.7399237825953712,

‘Training Accuracy scores’: array([0.79592173, 0.79496809,
0.79532611, 0.79507888, 0.79554525, 0.79680492, 0.79661895,
0.79598324, 0.79446701, 0.79578551]),
‘Training F1 scores’: array([0.79592173, 0.79496809, 0.79532611,
0.79507888, 0.79554525, 0.79680492, 0.79661895, 0.79598324,
0.79446701, 0.79578551]),
‘Training Precision scores’: array([0.79592173, 0.79496809,
0.79532611, 0.79507888, 0.79554525, 0.79680492, 0.79661895,
0.79598324, 0.79446701, 0.79578551]),
‘Training Recall scores’: array([0.79592173, 0.79496809, 0.79532611,
0.79507888, 0.79554525, 0.79680492, 0.79661895, 0.79598324,
0.79446701, 0.79578551]),
‘Validation Accuracy scores’: array([0.73734378, 0.74009744,
0.73898305, 0.74364407, 0.74229098, 0.73815831, 0.73908436,
0.73590504, 0.74531002, 0.73842077]),
‘Validation F1 scores’: array([0.73734378, 0.74009744, 0.73898305,
0.74364407, 0.74229098, 0.73815831, 0.73908436, 0.73590504,
0.74531002, 0.73842077]),
‘Validation Precision scores’: array([0.73734378, 0.74009744,
0.73898305, 0.74364407, 0.74229098, 0.73815831, 0.73908436,
0.73590504, 0.74531002, 0.73842077]),
‘Validation Recall scores’: array([0.73734378, 0.74009744,
0.73898305, 0.74364407, 0.74229098, 0.73815831, 0.73908436,
0.73590504, 0.74531002, 0.73842077])




Рисунок 2.10 - Результаты KNN

Результаты для Древа Решений (Decision Tree)(2.11):

'Mean Training Accuracy': 99.72581287826799,
 'Mean Training F1 Score': 0.9972581287826798,
 'Mean Training Precision': 0.9972581287826798,
 'Mean Training Recall': 0.9972581287826798,
 'Mean Validation Accuracy': 78.37570534396792,
 'Mean Validation F1 Score': 0.7837570534396793,
 'Mean Validation Precision': 0.7837570534396793,
 'Mean Validation Recall': 0.7837570534396793,

'Training Accuracy scores': array([0.9972686 , 0.99724505,
 0.99722157, 0.99726866, 0.9971628, 0.99731585, 0.9973512 ,
 0.99713929, 0.99724528, 0.997363]),
 'Training F1 scores': array([0.9972686 , 0.99724505, 0.99722157,
 0.99726866, 0.9971628, 0.99731585, 0.9973512 , 0.99713929,
 0.99724528, 0.997363]),
 'Training Precision scores': array([0.9972686 , 0.99724505,
 0.99722157, 0.99726866, 0.9971628, 0.99731585, 0.9973512 ,
 0.99713929, 0.99724528, 0.997363]),
 'Training Recall scores': array([0.9972686 , 0.99724505, 0.99722157,
 0.99726866, 0.9971628, 0.99731585, 0.9973512 , 0.99713929,
 0.99724528, 0.997363]),
 'Validation Accuracy scores': array([0.7841559 , 0.7808727 ,
 0.78866525, 0.78506356, 0.78404154, 0.77948501, 0.78709199,

0.78401865, 0.78399576, 0.78018018]],
 'Validation F1 scores': array([0.7841559 , 0.7808727 , 0.78866525,
 0.78506356, 0.78404154, 0.77948501, 0.78709199, 0.78401865,
 0.78399576, 0.78018018]),
 'Validation Precision scores': array([0.7841559 , 0.7808727 ,
 0.78866525, 0.78506356, 0.78404154, 0.77948501, 0.78709199,
 0.78401865, 0.78399576, 0.78018018]),
 'Validation Recall scores': array([0.7841559, 0.7808727, 0.78866525,
 0.78506356, 0.78404154, 0.77948501, 0.78709199, 0.78401865,
 0.78399576, 0.78018018])




Рисунок 2.11 - Результаты Древа решений

Результаты для Случайного леса (Random Forest)(Рис.2.12):

'Mean Training Accuracy': 99.19160516896157,
 'Mean Training F1 Score': 0.9919160516896157,
 'Mean Training Precision': 0.9919160516896157,
 'Mean Training Recall': 0.9919160516896157,
 'Mean Validation Accuracy': 80.31363019866926,
 'Mean Validation F1 Score': 0.8031363019866926,
 'Mean Validation Precision': 0.8031363019866926,
 'Mean Validation Recall': 0.8031363019866926,
 'Training Accuracy scores': array([0.99175857, 0.99175857,
 0.99195511, 0.99219077, 0.99188991, 0.99225617, 0.99233486,
 0.99141923, 0.99173327, 0.99186407]),

‘Training F1 scores’: array([0.99175857, 0.99175857, 0.99195511,
 0.99219077, 0.99188991, 0.99225617, 0.99233486, 0.99141923,
 0.99173327, 0.99186407]),
 ‘Training Precision scores’: array([0.99175857, 0.99175857,
 0.99195511, 0.99219077, 0.99188991, 0.99225617, 0.99233486,
 0.99141923, 0.99173327, 0.99186407]),
 ‘Training Recall scores’: array([0.99175857, 0.99175857, 0.99195511,
 0.99219077, 0.99188991, 0.99225617, 0.99233486, 0.99141923,
 0.99173327, 0.99186407]),
 ‘Validation Accuracy scores’: array([0.80115308, 0.80597717,
 0.80331921, 0.80162468, 0.79868142, 0.8032729 , 0.81017428,
 0.80204899, 0.80544106, 0.79967024]),
 ‘Validation F1 scores’: array([0.80115308, 0.80597717, 0.80331921,
 0.80162468, 0.79868142, 0.8032729 , 0.81017428, 0.80204899,
 0.80544106, 0.79967024]),
 ‘Validation Precision scores’: array([0.80115308, 0.80597717,
 0.80331921, 0.80162468, 0.79868142, 0.8032729 , 0.81017428,
 0.80204899, 0.80544106, 0.79967024]),
 ‘Validation Recall scores’: array([0.80115308, 0.80597717,
 0.80331921, 0.80162468, 0.79868142, 0.8032729 , 0.81017428,
 0.80204899, 0.80544106, 0.79967024])




Рисунок 2.12 - Результаты для Случайного леса

Результаты для Multi-Layer Perceptron (Рис.2.13):

‘Mean Training Accuracy’: 58.04541422380254,

'Mean Training F1 Score': 0.5804541422380254,
 'Mean Training Precision': 0.5804541422380254,
 'Mean Training Recall': 0.5804541422380254,
 'Mean Validation Accuracy': 0.5787026701520374,
 'Mean Validation F1 Score': 0.5787026701520374,
 'Mean Validation Precision': 0.5787026701520374,
 'Mean Validation Recall': 0.5787026701520374,

'Training Accuracy scores': array([0.58954186, 0.58101772,
 0.57247298, 0.58468976, 0.57454839]),
 'Training F1 scores': array([0.58954186, 0.58101772, 0.57247298,
 0.58468976, 0.57454839]),
 'Training Precision scores': array([0.58954186, 0.58101772,
 0.57247298, 0.58468976, 0.57454839]),
 'Training Recall scores': array([0.58954186, 0.58101772, 0.57247298,
 0.58468976, 0.57454839]),
 'Validation Accuracy scores': array([0.58737221, 0.57898082,
 0.57321466, 0.57923179, 0.57471386]),
 'Validation F1 scores': array([0.58737221, 0.57898082, 0.57321466,
 0.57923179, 0.57471386]),
 'Validation Precision scores': array([0.58737221, 0.57898082,
 0.57321466, 0.57923179, 0.57471386]),
 'Validation Recall scores': array([0.58737221, 0.57898082,
 0.57321466, 0.57923179, 0.57471386])




Рисунок 2.13 - Результаты Multi-Layer Perceptron

Подготовка данных. Для подготовки данных, необходимых для разработки моделей были проделаны следующие работы (Рис.2.14):

1. Были собраны данные с передающего оборудования, расположенного в машине для 3-х участников эксперимента. Общее количество данных: 73 800 строк.

2. На первого водителя были собраны 70081 (так как количество поездок было больше), на третьего водителя 3870 строк данных.

3. Данные имели следующие поля: ‘_id’, ‘devicename’, ‘peer’, ‘batterycurrent’, ‘batteryvoltage’, ‘channelid’, ‘deviceid’, ‘devicetypeid’, ‘engineignitionstatus’, ‘eventpriorityenum’, ‘externalpowersourcevoltage’, ‘gpsfuelused’, ‘gsmcc’, ‘gsmnc’, ‘gsmoperatorcode’, ‘gsmlevel’, ‘ident’, ‘movementstatus’, ‘positionaltitude’, ‘positiondirection’, ‘positionlatitude’, ‘positionlongitude’, ‘positionsatellites’, ‘positionspeed’, ‘protocolid’, ‘servertimestamp’, ‘timestamp’, ‘tripstatus’, ‘xacceleration’, ‘yacceleration’, ‘zacceleration’, ‘eventenum’, ‘canambientairtemperature’, ‘canenginerpm’, ‘canfuellevel’, ‘canvehiclespeed’, ‘harshcorneringangle’, ‘harshcorneringevent’, ‘absoluteacceleration’, ‘harshaccelerationevent’, ‘overspeedingspeed’, ‘canenginecoolanttemperature’, ‘canthrottledallevel’, ‘canengineloadlevel’, ‘canshortfueltrim’, ‘canmaffairflowrate’, ‘harshbrakingevent’, ‘ecodrivingeventduration’

4. Далее над данными были сделаны работы по подбору признаков (feature engineering):

i. На первом этапе данные были визуально изучены и удалены явные признаки (‘_id’, ‘devicename’, ‘peer’), которые не могут быть использованы для построения модели;

ii. На втором этапе данные с первого этапа были пропущены через алгоритм нахождения низкой дисперсии (low variance). Это делается для того чтобы удалить признаки с низкой дисперсией, так как значения в таких атрибутах в основном одинаковые, и на этапе обучения модели такие данные не имеют влияния на нахождение каких-либо закономерностей. После данного этапа остались 28 признаков из 48 изначальных: ‘engineignitionstatus’, ‘externalpowersourcevoltage’, ‘gpsfuelused’, ‘gsmcc’, ‘gsmoperatorcode’, ‘gsmlevel’, ‘movementstatus’, ‘positionaltitude’, ‘positiondirection’, ‘positionsatellites’, ‘positionspeed’, ‘servertimestamp’, ‘timestamp’, ‘tripstatus’, ‘xacceleration’, ‘eventenum’, ‘ca

‘nambientairtemperature’, ‘canenginerpm’, ‘canfuellevel’, ‘canvehiclespeed’, ‘harshcorneringangle’, ‘overspeedingspeed’, ‘canenginecoolanttemperature’, ‘canthrottlepedallevel’, ‘canengineloadlevel’, ‘canshortfueltrim’, ‘canmafairflowrate’, ‘ecodrivingeventduration’

iii. Следующим этапом является нахождение признаков с отсутствующими значениями (missing values), но так как в нашем наборе не так много отсутствующих значений (некоторые из них были на уже удаленных полях) мы пропустили данный этап.

iv. После удаления избыточных признаков на первых этапах мы выполнили выбор признаков, исключаящих сильно коррелированные признаки для повышения производительности с точки зрения точности и скорости. Самый простой способ обнаружить сильно коррелированные признаки — использовать корреляцию Пирсона и удалить слишком (~90%) коррелированные признаки (Рис. 1.6). В нашем случае были “servertimestamp”, “overspeedingspeed”, “positionspeed”, “positionaltitude”, “externalpowersourcevoltage”, “timestamp”, “gsm signallevel”, “gsmoperatorcode”, “gsmmcc” “engineignitionstatus”, “eventnum”.




Рисунок 2.14 - Корреляция признаков

5. Признаки имеют разные измерения и амплитуды, поэтому необходима нормализация данных для одинаковой обработки алгоритма классификации. В частности, процесс нормализации необходим для запуска алгоритмов, основанных на расстоянии между данными, например, как алгоритм KNN.

$$X_i = (x_i - \min(x_i)) / \max(x_i) - \min(x_i)$$

Для нормализации значений мы используем уравнение (1) в диапазоне от 0 до 1. В уравнении $\min$ — это минимальное значение данных признаков, а $\max$ — максимальное значение признаков соответственно.

2.2.3 Динамическая модель максимизации прибыли

Целью исследования является разработка модели максимизации прибыли для системы каршеринга, учитывающей географические и экономические особенности региона. Разрабатывается динамическая модель, позволяющая повысить эффективность функционирования системы каршеринга за счет учета изменения распределения потенциальных клиентов со временем в определенном регионе. Следствием этого является рост доходов системы каршеринга и развития региона в целом.

Для достижения цели были поставлены следующие задачи:

- описать способ покрытия определенного региона геометрическими фигурами разных площадей, что позволяет разбить регион на субрегионы;
- установить количественные параметры каждого подрегиона, которые существенны для построения динамической модели максимизации прибыли для системы каршеринга;
- построить целевую функцию максимизации прибыли в динамической модели и установить ограничения с учетом географических и экономических особенностей региона.

Материалы и методы исследования

Обеспечение эффективного функционирования каршеринга зависит от учета географических и экономических характеристик региона, в котором эта система реализуется. Также важной составляющей эффективности является учет данных характеристик в динамике. Для формализации параметров модели была использована теория множеств. Для покрытия площади региона был использован метод гексагональной тесселяции. Для создания модели максимизации

прибыли была использована теория дискретной оптимизации.

Данные для проведения исследования (координаты начала и завершения поездки, время поездки и другие) были взяты из открытого источника [68]. Данные включают информацию о поездках такси четырех крупнейших служб г. Нью-Йорк. Поскольку каршеринг является альтернативой службе такси, можно считать, что поведение клиентов системы каршеринга будет подобным, то есть поездки будут совершаться по схожим маршрутам.

Динамическая модель максимизации прибыли для системы каршеринга. Способ покрытия региона геометрическими фигурами.

Для построения модели максимизации доходов системы каршеринга кроме экономических параметров нужно учесть географические. Для этого регион, выбранный для реализации системы, нужно разбить на субрегионы. Для каждого подрегиона можно рассчитать параметры, необходимые для принятия оперативных решений по реализации системы.

Распространены несколько способов представления и хранения геоинформационных данных. Самым простым способом является сохранение списка объектов, каждый из которых сохраняет свои координаты как одно из свойств. Этот способ хранения данных имеет ряд недостатков. В частности, сложно находить соседние точки и строить маршруты передвижения автомобилей. Также способ представления данных с сохранением координат объектов значительно усложняет анализ данных в некоторых частях региона. Для решения таких задач значительно лучше подходит способ представления данных, когда исследуемый регион покрывается сеткой, а свойства объектов сохраняются в ячейке сетки, которая их покрывает.

Актуальной задачей является выбор метода покрытия региона ячейками сетки. Традиционным методом является административный, когда границы ячеек определяются улицами, границами городов, географическими объектами, районами городов и другие. Административный метод наиболее точно отражает данные о реальном мире. Существенным недостатком административного метода является сложная форма границ ячеек. Ведь для сохранения границы региона как ломаной, сплайна или другой линии требует значительных объемов данных. Также многообразие границ ячеек существенно усложняет алгоритмы их обработки.

Решить задачу сложности обработки ячеек позволяют методы

тесселяции однородными сетками. Основой методов тесселяции является покрытие региона сеткой, каждая ячейка которой имеет форму правильного n -угольника, в частности треугольника, квадрата, шестиугольника [69].

Для покрытия определенного региона геометрическими фигурами разных площадей, позволяющими разбить регион на субрегионы, были проанализированы фреймворки H3 от компании Uber [70] и S2 от Google [71]. В результате сравнения (табл. 1.2) установлено, что оба фреймворка покрывают всю поверхность Земли, поэтому могут быть использованы для покрытия любого региона. Также оба фреймворка позволяют выбрать масштаб сетки в очень широких пределах. Оба фреймворка являются Open source проектами от известных международных компаний. Единственным существенным отличием между фреймворками H3 и S2 является форма решетки. Основное преимущество покрытия сеткой с шестиугольными ячейками состоит в том, что расстояние между центрами соседних ячеек является постоянным. Данное свойство существенно упрощает алгоритмы нахождения кратчайших путей между ячейками.

Таблица 1.2 - Сравнение фреймворков H3 и S2

Характеристика	Фреймворк H3	Фреймворк S2
Покрываемое покрытие	Весь мир	Весь мир
Лицензия	Open source	Open source
Ячейка	Шестиугольник	Квадрат
Количество уровней масштаба	16	31
Минимальный размер ячейки	0,5 м.	0.01 м
Максимальный размер ячейки	1 107 км	21 477 км

При моделировании системы каршеринга расстояния и маршруты поездок важны. Поэтому авторы считают, что при моделировании системы каршеринга целесообразно покрывать регион решеткой из равных правильных шестиугольников, расположенных сторона к стороне.

Для покрытия карты шестиугольниками с использованием фреймворка H3, прежде всего, необходимо указать границы региона. Были использованы данные о границах регионов, предоставляемых сервисом GADM [72]. Данные предоставляются в

формате .gprkg. Для каждой страны составлен список секторов, содержащий данные о том, какому городу, району или области принадлежит данный сектор, а также описание границы сектора. Граница сектора описывается как многоугольник с заданными вершинами. Координаты вершин сохраняются в формате географических координат (пары длина и ширина).

Для выбранной области покрытие шестиугольниками соответствующего масштаба осуществляется с использованием функции polyfill, входящей в фреймворк НЗ. Результатом является список идентификаторов шестигранников, покрывающих указанную область. Для визуализации покрытия использован сервис Kepler [73].

Определение количественных параметров каждого подрегиона, которые существенны для построения динамической модели

Была проанализирована интегрированная система для оптимизации перемещения транспортных средств и персонала [74] и выделены ключевые параметры, которые значимы для максимизации прибыли системы каршеринга.

В системе [74] не учитывается изменение параметров во времени. Однако следует отметить, что аренда автомобилей клиентами меняется периодически в разные дни недели, время суток и другие. Это нужно учесть. Поэтому рассмотрим следующие параметры:

T – количество периодов, на которые разбивается цикл работы каршеринга. После прохождения цикла считаем, что система возвращается в исходное состояние, в частности может изменяться локализация автомобилей. Рассматривается время дискретное $\langle t_0, t_1, \dots, t_T \rangle$. В дальнейшем для простоты записи, будем считать, что $t_m = m$, $m = 0, T$.

Пусть задан регион O , покрытый подрегионами $O_1, O_2, \dots, O_n$.

Для каждого подрегиона O_i определим в каждый момент времени t следующие параметры:

$K_i(t)$ – количество занятых машин в подрегионе O_i в момент времени t ;

$k_i(t)$ – количество свободных машин в подрегионе O_i в момент времени t ;

$C_{ij}(t)$ – количество машин, уехавших из подрегионов в O_j

подрегион O_j за промежуток времени $[t-1, t)$

$p_{ij}(t)$ – вероятность поездки машины с подрегионом в O_i подрегион O_j в момент времени t ;

$l_i(t)$ – затраты на обслуживание автомобилей в подрегионе O_i в момент времени t (ремонт, мойка и другие);

$P_{ij}(t)$ – стоимость поездки машины с подрегионом в O_i подрегион O_j в момент времени t можно определить по формуле:

$$P_{ij}(t) = \tau(t) \cdot r_{ij},$$

где $\tau(t)$ – тариф на количество подрегионов, проезжающих автомобиль из подрегиона O_i в подрегион O_j в момент времени t , r_{ij} – длина маршрута при поездке с подрегионом в O_i подрегион O_j ;

$L_{ij}(t)$ – расходы поездки автомобиля с подрегионом в O_i подрегион O_j в момент времени t можно определить по формуле:

$$L_{ij}(t) = \beta \cdot r_{ij} \cdot C_{ij}(t),$$

где β – коэффициент, учитывающий стоимость горючего (сколько расходуется средств на топливо для проезда в соседний подрегион).

Для оценки параметров системы использованы данные из открытых источников. В частности, использован набор данных о поездках такси в г. Нью-Йорк, США, которые получены с помощью сервиса TLC [75]. Данный набор данных содержит данные о поездках пассажиров в четырех службах такси за период с января 2009 по июль 2021 года. С 2016 года доступны данные о времени и координатах начала поездки, времени и координатах завершения поездки, стоимости поездки, количестве пассажиров.

Для вычисления вероятности поездки автомобиля из подрегиона O_i в подрегион O_j за промежуток времени $[t-1, t)$ использованы данные о поездках с января 2016 по июль 2021 года. В общей сложности были обработаны данные о 787 666 242 поездках.

Данные об 11 381 172 поездках, которые содержали ошибочные данные, в частности координаты равные 0, не брались в рассмотрение. Для вычисления параметров модели были использованы данные о 776 285 070 поездках. Координаты посадки и высадки изображены на рис.2.15, рис.2.16.




Рисунок 2.15 - Координаты начала поездок по данным служб такси г. Нью-Йорк



Рисунок 2.16 - Координаты завершения поездок по данным служб такси г. Нью-Йорк

Координаты начала и завершения каждой из поездок отнесены к соответствующим шестиугольникам покрытия. Вероятность поездки, согласно статистическому определению вероятности, рассчитывается как отношение количества поездок из подрегиона o_i в подрегион o_j к общему количеству поездок.

На Рисунке 2.17 показана карта поездок с привязкой к гексагональной решетке. Количество поездок отображается цветом.




Рисунок 2.17 - Карта поездок такси с привязкой к гексагональной решетке в г. Нью-Йорк

Согласно отчету [76] стоимость проезда одной мили в трех службах каршеринга г. Нью-Йорк составляет от 0,35\$ до 0,59\$. Учитывая, что при масштабе равном 8, стороны шестиугольника сетки, построенной с использованием фреймворка H3, составляет 461 метр получаем, что значения должны находиться в пределах $0,15 \leq \tau(t) \leq 0,3$.

Согласно данным себестоимость проезда одной мили изменялась от 0,12\$ в 2016 году до 0,174\$ в 2021 году. Поэтому коэффициент можно оценить в пределах от 0,05 до 0,07. При построении модели было принято, что $\beta=0,06$.

Построение целевой функции и ограничений динамической модели максимизации прибыли для системы каршеринга

При определении целевой функции задачи максимизации

прибыли для системы каршеринга нужно указать все источники доходов и расходы на реализацию системы. То есть, учитывая определенные параметры для каждого подрегиона, можно записать функцию:

$$\sum_{i=1}^n \sum_{j=1}^n \sum_{t=1}^T P_{ij}(t) - \sum_{i=1}^n \sum_{j=1}^n \sum_{t=1}^T L_{ij}(t) - \sum_{i=1}^n \sum_{t=1}^T l_i(t) \rightarrow \max, \quad (1)$$

где $\sum_{i=1}^n \sum_{j=1}^n \sum_{t=1}^T P_{ij}(t)$ – доход, полученный от всех поездок из каждого региона о_i в регион о_j, $i = \overline{1, n}$ за весь период времени $t = \overline{1, T}$, $j = \overline{1, n}$

$\sum_{i=1}^n \sum_{j=1}^n \sum_{t=1}^T L_{ij}(t)$ – расходы на все поездки из каждого региона о_i в регион о_j, $i = \overline{1, n}$, $j = \overline{1, n}$ за весь период времени $t = \overline{1, T}$,

$\sum_{i=1}^n \sum_{t=1}^T l_i(t)$ – расходы на обслуживание автомобилей в каждом регионе о_i, $i = \overline{1, n}$ за весь период времени $t = \overline{1, T}$.

Задача состоит в нахождении оптимального распределения автомобилей в подрегионах в начальный момент времени. В последующие моменты времени распределение автомобилей по подрегионам определяется на основе условий (2)–(6). С ростом T утрачивается влияние значений начальных параметров на результат оптимизации. Поэтому при $T > 50$ эффект от оптимизации первоначального размещения автомобилей будет на уровне погрешности. Целесообразно рассматривать динамическую модель для небольших значений T , $T \leq 10$.

Следует учесть ограничения, в частности, что все автомобили на начальном этапе нужно распределить по подрегионам:

$$\sum_{i=1}^n k_i(0) = k, \quad (2)$$

$$\sum_{i=1}^n k_i(t) \leq k, \quad t = \overline{1, T}, \quad (3)$$

где k – общее количество автомобилей в системе каршеринга,

$k_i(0)$ – количество свободных автомобилей в начальный момент времени в регионе o_i , $k_i(t)$ – количество свободных автомобилей за промежуток времени $[t-1, t)$ в регионе o_i , $i = \overline{1, n}$.

Установим ограничения на то, что количество автомобилей, которые клиенты могут использовать для поездки из региона o_i в другие регионы, не может превышать количество свободных автомобилей в регионе:

$$\sum_{h=1}^n C_{ih}(t) = k_i(t-1) + \sum_{h=1}^n C_{hj}(t-1) - \sum_{h=1}^n C_{ih}(t-1), \quad (4)$$

$$C_{ij}(0) = 0, \quad (5)$$

где $C_{ih}(t)$ – количество автомобилей, уехавших из региона o_i в регион o_h за промежуток времени $[t-1, t)$, $h = \overline{1, n}$,

$C_{ih}(t-1)$ – количество автомобилей, уехавших из региона o_i в регион o_h за промежуток времени $[t-2, t-1)$, $h = \overline{1, n}$,

$C_{hj}(t-1)$ – количество автомобилей, приехавших в регион o_j из региона o_h за промежуток времени $[t-2, t-1)$, $h = \overline{1, n}$,

$k_i(t-1)$ – количество свободных автомобилей за промежуток времени $[t-2, t-1)$ в регионе o_i , $i = \overline{1, n}$,

$C_{ij}(0) = 0$ – условие определяет, что в начальный момент времени автомобили не совершают поездки.

Построим ограничения, определяющие зависимость между априорной вероятностью поездки машины из региона o_i в регион o_j и количеством свободных автомобилей в регионе o_i

$$\tilde{N}_{ij}(t) = f(p_{ij}(t), k_i(t-1)), \quad (6)$$

где $C_{ij}(t)$ – количество машин, уехавших из региона o_i в регион o_j за промежуток времени $[t-1, t)$, f – некоторая step-функция.

Функция – описывается $f(p_{ij}(t), k_i(t-1))$ аналитически сложно, поэтому для нахождения $\tilde{N}_{ij}(t)$ применим имитационное моделирование.

Для каждого подрегиона o_i и каждого свободного автомобиля в промежуток времени $[t-2, t-1)$ имитируем поездку. Для этого

$k_i(t-1)$ раз генерируем псевдослучайное число из промежутка $[0, 1)$. Если число попадает в промежуток $[0, p_{i1}(t))$, то имитируем поездку автомобиля в регион o_1 , если число попадает в промежуток $[p_{i1}(t), p_{i1}(t) + p_{i2}(t))$, то имитируем поездку автомобиля в регион o_2 и т.д., если число попадает в промежуток

$\left[\sum_{y=1}^{i-1} p_{iy}(t), \sum_{y=1}^i p_{iy}(t) \right)$, то имитируем поездку автомобиля в регион o_j , и

т.д., если число попадает в промежуток $\left[\sum_{y=1}^{n-1} p_{iy}(t), 1 \right)$, то имитируем поездку автомобиля в регион o_n .

Проведя процедуру имитационного моделирования, получаем целочисленную задачу линейного программирования (1)–(5). Для поиска решения данной задачи можно использовать приложение CPLEX [20].

Обсуждение результатов исследования по построению динамической модели максимизации прибыли для системы каршеринга

Построена динамическая модель максимизации прибыли для системы каршеринга с учетом экономических и географических особенностей региона. Географическая составляющая обеспечивается покрытием региона гексагональной решеткой, позволяющей разбить регион на субрегионы. Для этого использован фреймворк H3 [77], позволяющий подобрать разные масштабы для нужного количества субрегионов. Экономическая составляющая обеспечивается расчетом для каждого подрегиона ряда параметров, отражающих изменения в поведении клиентов в динамике. Динамическая модель максимизации доходов системы каршеринга (1) – (6) построена с учетом описанных динамических параметров. Преимуществом модели является ее динамический характер. В отличие от модели, которая описана в работе [78], построенная модель учитывает изменение спроса на поездки клиентов системы каршеринга в течение суток.

Построенная динамическая модель является однонаправленной, то есть затраты на распределение автомобилей по субрегионам после завершения цикла поездок в модели не учитываются. Эти издержки, как показано в работе [79], будут ненулевые. Ограничениями построенной динамической модели является то, что количество периодов времени и подрегионов должно быть небольшим. Это объясняется сложностью вычислений, которая для дискретной оптимизации будет экспоненциально возрастать. В работе не был рассмотрен подбор оптимального метода решения задачи (1) - (6), что является предметом дальнейших исследований.

Способ покрытия области геометрическими фигурами, разделяющими область на субрегионы. Для этой проблемы рациональным выбором было охватить область с правильными шестиугольниками, расположенными рядом. Набор данных с информацией о поездках по Астане построены. Затем мы построили карты начальных и конечных мест поездок в регионе, а также карту поездок, привязанную к ячейкам шестиугольной сетки, с помощью

сервиса визуализации Kepler. Каждая ячейка сетки соответствует определенному субрегиону, для которого рассчитываются количественные параметры, в том числе количество свободных автомобилей в субрегионах, вероятность поездки автомобиля из одного субрегиона в другой, затраты на содержание и эксплуатацию автомобилей, а также доход от поездки.

Определена целевая функция максимизации прибыли в динамической модели и установлены ограничения с учетом особенностей пассажирских перевозок в Астане. Моделирование проводилось на основе построенной модели максимизации прибыли системы каршеринга на примере Астаны. Для этого были рассмотрены два случая. Первый случай соответствует статической модели ($T = 1$), а второй — динамической модели ($T = 4$). Установлено, что использование динамической модели максимизации прибыли в системе каршеринга увеличивает прибыль на 3,7%.

В результате исследования город Астана в административных границах был покрыт шестиугольной сеткой. Для каждой ячейки сетки была собрана необходимая информация, анализ которой позволяет сделать следующие выводы:

1. На участках, ограниченных ячейками со многими пробегами (светлые ячейки на рисунке 4), следует размещать станции с более высокой пропускной способностью. Учредил. Это следует учитывать в плане развития города, поскольку под эти станции должны быть выделены соответствующие территории города.

2. Информация о количестве поездок на избирательные участки отражает спрос пользователей. Поскольку эта информация определяется для разного времени суток, спрос меняется циклически в течение недели, месяца и т.д. Соответственно, для эффективного функционирования системы каршеринга рекомендуется перемещать автомобили системы в станции определяются по ряду ячеек в нужный момент. Например, перемещение автомобилей в соответствующие районы рекомендуется утром и вечером, когда фиксируется исключительно высокий спрос, утром в жилые районы и вечером в деловые районы.

3. Описанная модель может быть рассмотрена администрацией города по градостроительству и частными компаниями, заинтересованными в максимизации прибыли от внедрения систем каршеринга в крупных городах, в частности в Астане.

2.3. Проектирование однорангового приложения, разработка модели и метода интеллектуального анализа данных для определения “безопасного стиля вождения”

2.3.1 Проектирование общей архитектуры предлагаемой системы

На следующей диаграмме (Рис.2.18) показана конструкция системы. Основные действующие лица, такие как Заказчик, Персонал, Хост, включены в архитектуру проектирования системы. Также внутренний сервер, база данных, балансировщик нагрузки можно рассматривать как часть дизайна системы. Сервер машинного обучения (ML) и API промежуточного программного обеспечения, которые соединяют внутренний сервер с сервером ML, также являются важной частью системы.




Рисунок 2.18 - Дизайн системной архитектуры

При запуске одноранговой системы совместного использования автомобилей может возникнуть широкий спектр рисков. Мы проиллюстрировали широко распространенные случаи в

следующей таблице. Вы можете видеть риски, частоту рисков, стоимость рисков, источник рисков, сценарии, которые обычно приводят к рискам, и соответствующие им решения (Приложение А).

2.3.2 Проектирование однорангового приложения каршеринга

Диаграмма последовательности (Рис.2.19). Следующая диаграмма иллюстрирует диаграмму последовательности действий, которую может выполнять Гость и владелец автомобиля. На основе схемы последовательности действий нарисованы основные действующие лица, которые будут задействованы, пока Гость и владелец автомобиля будут выполнять определенные действия. При этом можно увидеть последовательность действий с соответствующими запросами и ответами.




Рисунок 2.19 - Схема последовательности действий для гостя (пользователя) / клиента (часть 1)




Рисунок 2.20 - Схема последовательности действий для гостя (пользователя) / клиента (часть 2)

Традиционный каршеринг. При традиционном каршеринге мы владеем автомобилями и передаем их нашим клиентам. Ниже приведены варианты использования, которые могут делать наши клиенты (Рис.2.21). По сравнению с р2р, мы предлагаем иметь зону, где будут припаркованы автомобили, и клиенты смогут их забирать. На следующем рисунке показаны случаи, когда они обычно используются в традиционной системе каршеринга.




Рисунок 2.21 - Случаи, которые обычно используются в традиционной системе каршеринга

Подключение клиентов (KYC). Первое, что нужно учитывать, - это подключение клиентов. Подключение клиента - это подключение клиента к системе. Подключение подразумевает получение всех необходимых документов у клиента и регистрацию ключевых данных в базе данных. Для системы каршеринга необходимы следующие документы (возможно добавление дополнительных документов в соответствии с законодательством Республики Казахстан):

1. Удостоверение личности

2. Водительские права

Из этих данных важна следующая информация:

1. Идентификационный номер

2. Номер водительского удостоверения

3. Дата истечения срока действия водительских прав

После того, как эти данные будут преобразованы в электронную форму, их необходимо вставить в базу данных. Последовательность действий следующая:

1. Попросите пользователя сделать селфи, держа в руке удостоверение личности. В этом случае лицо человека должно быть обнаружено, и должно быть два лица: одно с селфи и одно с удостоверения личности. Обнаружив эти лица, мы должны сравнить эти лица и определить, принадлежат они одному и тому же человеку или нет. Вызов API должен возвращать «ошибку достоверного сходства», где значение, близкое к 0, означает высокое сходство, а значение, отличное от 0, означает низкое сходство. Чтобы принять решение, мы должны установить некоторое пороговое значение (например, 0,6), которое будет различать похожие и разные лица. Итак, если ошибка достоверного сходства меньше порогового значения, мы принимаем решение, что люди одинаковы (также возвращаем ошибку достоверного сходства), в противном случае мы принимаем решение, что люди разные (также возвращаем ошибку достоверного сходства) (рисунок 2.22).

2. Промежуточным шагом будет предоставление идентификационного номера правительственным организациям (через API), чтобы убедиться, что это лицо уплатило все налоги и не имеет криминального прошлого.

3. Убедившись, что лицо на селфи и в удостоверении личности одно и то же, мы можем начать просить человека предоставить фотографию удостоверения личности (рисунок 2.22). Фотография

удостоверения личности должна быть в высоком разрешении. Для большей точности рекомендуется установить прямоугольную рамку, в которую пользователи должны помещать свои удостоверения личности.

4. После того, как будет сделана фотография удостоверения личности, мы можем отправить ее в ML API для извлечения идентификационного номера. ML API обнаружит удостоверение личности, если оно не обрезано должным образом. Затем необходимо провести небольшую проверку на подделку. Как только он пройдет эту проверку, мы сможем определить область идентификационного номера и применить OCR. API вернет координаты ограничивающей рамки для обнаруженного идентификационного номера и идентификационного номера в виде строки. Вывод API должен быть в формате XML или json.




Рисунок 2.22 - Селфи с удостоверением личности, сравнение лиц и оценка ошибки сходства, удостоверение личности

5. После успешного завершения извлечения идентификационного номера мы можем перейти к следующему шагу - «извлечению ключевых данных из водительских прав». Если предыдущий модуль не прошел успешно, то просим снова и снова сделать снимок (всего 3 раза). Если после 3 попыток невозможно будет извлечь идентификационный номер, мы можем отправить этот КУС для ручной регистрации. Однако, если все в порядке, мы можем попросить участника сфотографировать свои водительские права. Разрешение фотографии должно быть высоким, чтобы мы могли извлечь все ключевые данные. Также рекомендуется иметь рамку, в которую участники будут помещать

свой документ.

6. После получения водительских прав мы отправляем его в ML API. ML API обнаружит водительские права, если они приняты неправильно. Затем мы проверяем подделку документа. После прохождения проверки мы можем определить номер водительского удостоверения и дату истечения срока его действия. Для обнаруженных объектов мы применяем OCR и преобразуем ключевые данные в строковую форму. Мы возвращаем объект JSON, который будет содержать ограничивающие рамки каждого обнаруженного объекта и соответствующую строку. Однако, если мы сталкиваемся с какими-либо проблемами, мы возвращаем строку ошибки с описанием ошибки. Затем участники должны пробовать снова и снова. Общее количество попыток будет 3. Если после 3 попыток участник снова столкнется с ошибкой, мы отправим KYC в ручную процедуру.

7. После того, как мы предоставим все данные приложению, на серверной стороне мы должны зарегистрировать участника и разрешить участнику начать водить машину.

Необходимые данные для модели машинного обучения

1. 2000 казахстанских удостоверений личности
2. 2000 казахстанских водительских прав

На следующем рисунке (рисунок 2.23) показана последовательность действий, которые пользователи должны предпринять, чтобы быть подключенными и совершить первую транзакцию для своих участников (**MFT - member first transaction**).

Первая транзакция участника (MFT) - это количество участников, совершивших хотя бы одну транзакцию. Мы будем использовать MFT как показатель успеха на протяжении всего проекта.




Рисунок 2.23 - Последовательность действий для подключения участника

Дизайн моделей машинного обучения

Ниже будет показан список конечных точек машинного обучения, необходимых для подключения KYC:

1. validate-user (таблица 1.3)




Рисунок 2.24

Таблица 1.3 - Описание конечной точки validateuser

Имя конечной точки	/validateuser
Метод	POST
Тип возврата	json
Параметры	username password <i>(имя пользователя и пароль необходимы для обеспечения безопасности API)</i> selfie_ic : URL изображения, на котором запечатлено селфи с удостоверением личности driver_license : URL изображения водительского удостоверения

Возвращение	similarityAB, similarityAC, similarityBC - оценка сходства между селфи, фотографией лица на удостоверении личности и фотографией лица из водительских прав. these_people_are: могут быть одинаковыми или разными на основе оценок подобия AB, подобия AC, подобия BC. error: если возникает ошибка определенного типа, она будет описывать ошибку.
Описание	Определяет, является ли человек на селфи, удостоверении личности и фотографии водительских прав одним и тем же человеком или нет.
Замечания	- Будет 3 лица, где 1) взято из селфи, 2) из удостоверения личности и 3) из водительских прав. - Ориентиры лица: бровь, губы, глаза и нос.

2. detect-ic (таблица 1.4)

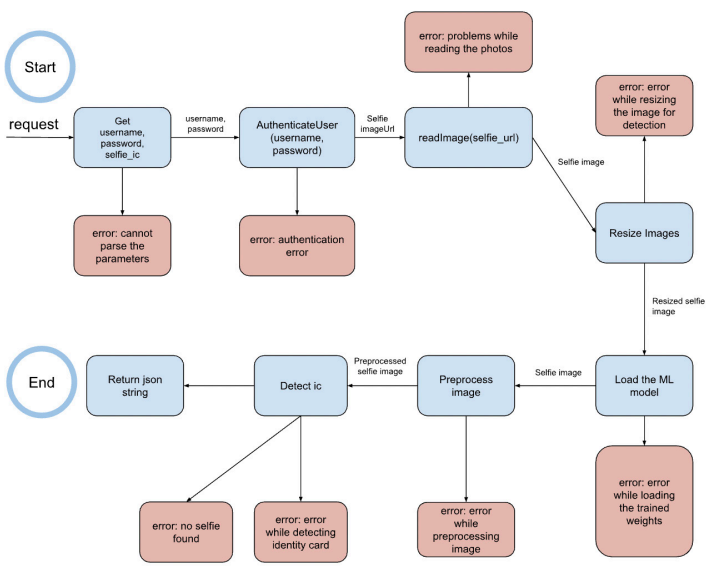


Рисунок 2.25

Таблица 1.4- Описание конечной точки detectic

Имя конечной точки	/detectic
Метод	POST
Тип возврата	Json
Параметры	Username, password <i>(имя пользователя и пароль необходимы для обеспечения безопасности API)</i> selfie_ic: URL изображения, на котором запечатлено селфи с удостоверением личности x1, y1, x2, y2: координаты центроидов найденных лиц <u>Примечание:</u> если $x1 = -1$ и $y1 = -1$ и $x2 = -1$ и $y2 = -1$, то это означает, что отправлено изображение только удостоверения личности и не найдено достаточное количество лиц.
Возвращение	y1, x1, y2, x2: координаты рамки удостоверения личности confidence_score: оценка достоверности обнаружения error: Если возникает ошибка определенного типа, она будет описана.
Описание	Определяет удостоверение личности по изображению
Замечания	1. Шкала достоверности варьируется от 0 до 1, где 1 означает наивысшую достоверность, 0 означает самую низкую достоверность. 2. Координаты центроидов найденных граней используются для проверки того, находится ли одна грань внутри IC, а вторая - за пределами границ IC.

3. detect-dl (таблица 1.5)




Рисунок 2.26

Таблица 1.5 - Описание конечной точки detectdl

Имя конечной точки	/detectdl
Метод	POST
Тип возврата	Json
Параметры	username password <i>(имя пользователя и пароль необходимы для обеспечения безопасности API)</i> driver_license : URL изображения водительского удостоверения

Возвращение	y1, x1, y2, x2: координаты рамки водительского удостоверения confidence_score: оценка достоверности обнаружения error: Если возникает ошибка определенного типа, она будет описана.
Описание	Определяет водительские права по изображению
Замечания	1. Шкала достоверности варьируется от 0 до 1, где 1 означает наивысшую достоверность, 0 означает самую низкую достоверность.

4. detect-ic-number




Рисунок 2.27

5. detect-driver-license-exp-date




Рисунок 2.28

6. validate-selfie




Рисунок 2.29

2.3.3 Модель определения безопасного стиля вождения

Дорожная безопасность остается важной проблемой в современном мире, требующей непрерывных улучшений. Одним из обещающих методов повышения безопасности дорожного движения является модель определения безопасного стиля вождения. В данном разделе представлена исследовательская работа, направленная на разработку инновационной модели определения безопасного стиля вождения с использованием передовых методов анализа данных и машинного обучения. Эта модель способствует снижению риска дорожных аварий и повышению дорожной безопасности в целом.

Дорожная безопасность – это одно из важнейших социальных и государственных приоритетов современного общества. Дорожные аварии и происшествия на дорогах, кроме человеческих потерь, также наносят значительные экономические убытки и обременяют систему здравоохранения. В связи с этим создание эффективных методов снижения риска дорожных происшествий и повышения безопасности на дорогах остается приоритетной задачей как для общества в целом, так и для государственных органов, академического сообщества и индустрии.

Один из инновационных методов, предлагаемых в данном разделе, – это модель определения безопасного стиля вождения. Понимание и анализ стиля вождения в реальном времени позволяют предоставлять водителям рекомендации и информацию, способствующие более безопасной эксплуатации автомобилей и снижению риска аварий. Такие модели сегодня становятся актуальными и доступными благодаря развитию сенсоров, технологий машинного обучения и обработки больших данных.

В данном исследовании представлены результаты по разработке модели определения безопасного стиля вождения, которая является частью более широких усилий в области дорожной безопасности. Мы подробно рассмотрим методологию, используемую для создания модели, а также обсудим ее потенциальные преимущества и вызовы.

В свете активного развития технологий и внедрения «умных» систем в автомобилях, создание такой модели представляет собой актуальное и перспективное направление в области дорожной безопасности. Введение подобных систем в повседневную практику вождения может существенно снизить риски и способствовать

сохранению человеческих жизней, а также экономическому благополучию общества.

Модель определения безопасного стиля вождения: Инновационный подход к повышению дорожной безопасности

Дорожная безопасность остается важной проблемой в современном мире, требующей непрерывных улучшений. Одним из обещающих методов повышения безопасности дорожного движения является модель определения безопасного стиля вождения. В данном разделе представлена исследовательская работа, направленная на разработку инновационной модели определения безопасного стиля вождения с использованием передовых методов анализа данных и машинного обучения. Эта модель способствует снижению риска дорожных аварий и повышению дорожной безопасности в целом.

Методы исследования

Для создания модели определения безопасного стиля вождения был использован многомерный подход, который включал в себя следующие этапы:

1. Сбор данных: Для сбора данных были использованы современные автомобили, оснащенные датчиками и камерами, способными непрерывно записывать информацию о движении, поведении водителя и окружающей среде. Эти данные включали в себя информацию о скорости, ускорении, расстоянии до других автомобилей, угле наклона руля и многие другие параметры.

2. Анализ данных: Собранные данные были подвергнуты комплексному анализу с использованием алгоритмов машинного обучения. Это позволило выявить паттерны поведения водителей, характеризующие безопасный и опасный стиль вождения.

3. Разработка модели: На основе анализа данных была разработана модель, способная в реальном времени оценивать стиль вождения водителя и выдавать рекомендации для его улучшения. Модель также учитывает факторы, такие как дорожные условия и погодные условия.

Модель определения безопасного стиля вождения на основе пороговых значений

Для определения безопасного вождения использовался GPS-трекер Teltonika, по другому данный термин называется эко-оценивание (eco-scoring). Eco-scoring в Teltonika GPS-трекерах представляет собой систему оценки экологичности стиля вождения водителя на основе множества параметров и данных, собираемых

с трекера. Эта система позволяет оценить, насколько водитель ведет себя экологически и эффективно при управлении автомобилем. Принцип работы Teltonika eco-scoring:

1. Сбор данных: GPS-трекер непрерывно собирает различные данные о движении автомобиля и поведении водителя. Эти данные могут включать в себя скорость движения, ускорение, замедление, повороты, простои, времена простоя, и даже обороты двигателя.

2. Анализ данных: Собранные данные передаются на сервер или облачную платформу, где они анализируются с использованием специальных алгоритмов. Эти алгоритмы учитывают различные аспекты стиля вождения, такие как резкие торможения, частые разгоны, соблюдение скоростных ограничений, и даже влияние экологических факторов на топливную эффективность.

3. Расчет оценки (эко-рейтинг): На основе анализа данных вычисляется экологичность вождения и формируется оценка или рейтинг, который отражает, насколько водитель соблюдает экологичные принципы при управлении автомобилем. Оценка может быть выражена в баллах, процентах или другой шкале.

4. Визуализация и обратная связь: Результаты оценки экологичности могут быть визуализированы и представлены как водителю, так и работодателю (если это используется для мониторинга профессиональных водителей). Водители могут видеть свои оценки и получать рекомендации по улучшению стиля вождения.

5. Улучшение экологичности вождения: Водители могут использовать обратную связь и рейтинги, чтобы совершенствовать свой стиль вождения и вести более экологично. Это может включать в себя более сглаженное ускорение и замедление, соблюдение скоростных ограничений, рациональное использование топлива и другие меры для снижения негативного воздействия на окружающую среду.

Представленная модель оценки основанный на пороге (threshold-based) может быть представлена в следующем виде:

$$Eco - Score = \frac{N_{\text{соблюдённых критериев}}}{N_{\text{всех критериев}}} \times 100\%$$

В модели:

- Eco-Score - Экологический рейтинг (Eco-Score), выраженный в процентах.

- N (соблюдённых критериев) - Количество критериев (параметров), которые водитель успешно соблюдает, то есть значение каждого параметра находится в пределах установленных пороговых значений.

- N (всех критериев) - Общее количество критериев (параметров), которые используются для оценки экологичности вождения.

Параметры, входящие в оценку, могут варьироваться в зависимости от системы оценки и требований. При реализации данной системы были включены скорость движения, ускорение, резкие торможения, максимальное угловое ускорение. При настройке системы выстраиваются пороги:

- Максимальное ускорение (m/s^2)
- Максимальное торможение (m/s^2)
- Угловая скорость (rad/s)
- Скорость движения (km/час) из GPS.

Каждый параметр имеет свой пороговый уровень, который определяется на основе экологических и безопасных норм. Если значение параметра находится в пределах установленного порога, то он считается соблюденным, и это увеличивает числитель N (соблюдённых критериев). Если значение параметра превышает порог, то он считается нарушенным. В итоге значение “Eco-Score” (Рис.2.30) определяется как процент успешно соблюденных критериев относительно общего числа критериев.

Важно отметить, что конкретные пороговые значения и параметры, а также методика расчета могут различаться в разных системах оценки экологичности вождения.

2.3.4 Анализ поведения водителя используя данные телематики и моделей глубокого обучения

Скорость урбанизации во всем мире создает дополнительную нагрузку на городские инфраструктурные сети, в том числе транспортные системы. Хорошо развитая система общественного транспорта в Лондоне помогает минимизировать неравенство мобильности между различными группами населения. Широкое распространение автотранспорта в городах, зависящих от автомобилей, включая Дубай и Астану, а также во многих американских городских районах, приводит к заторам на дорогах, загрязнению воздуха и повышению риска дорожно-транспортных происшествий. Всемирная организация здравоохранения сообщает, что человеческая ошибка ежегодно становится причиной более 1,19 миллиона смертей в результате дорожно-транспортных происшествий во всем мире. Цели устойчивого развития ООН включают повышение безопасности дорожного движения в качестве глобального приоритета посредством инициатив SDG 3.6 и SDG 11.2 и Vision Zero. Технологии предоставляют масштабируемые решения, выходящие за рамки инфраструктурных и правовых реформ. Исследование изучает методы оценки на основе мобильных устройств, которые используют данные сенсоров смартфонов для оценки поведения водителя. Эти системы повышают уровень знаний водителя, одновременно снижая вероятность аварий. Алгоритмы машинного обучения демонстрируют превосходную производительность при обнаружении небезопасного поведения на основе данных временных рядов по сравнению с традиционными системами на основе правил, поскольку они предлагают лучшую адаптивность и точность.

Материалы и методы. Набор данных и исследовательский анализ. В этом исследовании используется общедоступный набор данных Driving Behavior Dataset, разработанный для классификации агрессивного вождения с использованием данных инерционного датчика. Он включает шесть характеристик временного ряда, зарегистрированных модулем датчика MPU6050 — трехосевой акселерометр (AccX , AccY , AccZ) и гироскоп (GyroX , GyroY , GyroZ). Данные были собраны в реальных условиях вождения с использованием трех транспортных средств (Ford Fiesta 1.4, Ford Fiesta 1.25 и Hyundai i20), каждое из которых управлялось тремя разными водителями. Такое разнообразие повышает

обобщаемость обучения модели. Каждый образец помечен одним из четырех агрессивных маневров вождения : внезапное ускорение, резкое торможение, резкий поворот направо и резкий поворот налево. Первоначальный разведывательный анализ данных включал гистограммы (рисунок 2.32) и корреляционную тепловую карту Пирсона (рисунок 2.33). Распределения показали асимметрию в GyroZ и AccZ , что указывает на частые резкие маневры. Корреляционный анализ выявил сильные взаимосвязи между GyroZ и AccY ($r = 0,82$) и умеренную обратную взаимосвязь между GyroX и GyroZ ($r = -0,46$), что дает представление о динамическом поведении транспортного средства и информирует об архитектуре модели.




Рис. 2.32. Гистограмма по признакам




Рис.2.33. Тепловая карта корреляции Пирсона

Предварительная обработка данных. Предварительная обработка данных началась с удаления неполных или шумных образцов датчиков для обеспечения целостности набора данных. Все признаки были стандартизированы с использованием нормализации z-оценки (уравнение 1), что привело к среднему значению, равному нулю, и дисперсии, равной единице на признак. Для сохранения временной динамики был применен подход скользящего окна, сегментирующий сигнал на перекрывающиеся последовательности из 14 временных шагов (~7 секунд). Каждое окно было помечено на основе последнего временного шага, отражающего доминирующее поведение в конце последовательности. Метки классов сначала были закодированы как целые числа,

а затем преобразованы в one-hot векторы для согласования с категориальной функцией потери кросс-энтропии. Наконец, набор данных был разделен на обучающие и тестовые подмножества с использованием соотношения 70/30 при сохранении баланса классов для обеспечения справедливой оценки.

$$x' = \frac{(x - \mu)}{\sigma} \quad (1)$$

Использование моделей глубокого обучения для задач последовательной классификации широко распространено, поскольку они отлично справляются с моделированием сложных временных отношений в данных временных рядов [19, 20]. Исследование выбрало архитектуры LSTM, GRU и 1D-CNN, поскольку они показали успех в сопоставимых приложениях. LSTM выступает в качестве базовой, но мощной модели для моделирования временных рядов, несмотря на свою прямолинейную природу.

1. Долгосрочная краткосрочная память (LSTM). Модель LSTM содержала один слой LSTM с 64 скрытыми единицами, за которым следовал плотный слой с активацией ReLU и последний выходной слой softmax для классификации (рисунок 2.34). После слоя LSTM был применен слой исключения со скоростью 0,3 для предотвращения переобучения. Входные, забывающие и выходные вентили в сетях LSTM позволяют этим моделям изучать долгосрочные зависимости в последовательных данных, что делает их подходящими для задач моделирования временных рядов.




Рис. 2.34. Архитектура LSTM




Рис. 2.35. Архитектура GRU

2. 1D сверточная нейронная сеть (CNN). Архитектура CNN была разработана для захвата локальных временных закономерностей в данных временных рядов. Она включала одномерный сверточный слой с 64 фильтрами и размером ядра 3, за которым следовали максимальное объединение, отсев (скорость = 0,3), выравнивание и плотный выходной слой (рисунок 5). CNN выгодны с точки зрения скорости обучения и распараллеливания и особенно эффективны при извлечении краткосрочных зависимостей в последовательных входах.




Рис. 2.36. Архитектура одномерной сверточной нейронной сети (CNN)

3. Gate Recurrent Unit (GRU). Модель GRU приняла ту же архитектуру, что и модель LSTM, заменив слой LSTM слоем GRU, который имел 64 блока (рисунок 2.35). Все остальные архитектурные компоненты остались неизменными. GRU упрощают внутренние механизмы LSTM, объединяя вентили забывания и ввода в один вентиль обновления, уменьшая количество параметров и вычислительных требований, сохраняя при этом высокую производительность при моделировании временных последовательностей.

Протокол обучения и оценки. Оптимизатор Adam (скорость обучения = 0,001) и категориальная кросс-энтропия использовались в качестве функции потерь для всех моделей. Они обучались в течение 20 эпох с размером партии 32. Ранняя остановка или планирование скорости обучения не использовались, чтобы гарантировать, что оценки всегда были одинаковыми. Используя стратифицированную выборку для сохранения распределения классов, набор данных был разделен на обучающий (70%) и

проверочный (30%) наборы. Мы отслеживали, как точность обучения и проверки , а также потери изменялись в каждой эпохе, чтобы контролировать ход обучения моделей. На рисунке 2.37 показаны результаты для модели LSTM.




Рис. 2.37. Кривые точности и потерь обучения и проверки для модели LSTM

Кривые обучения показывают, что модель стабильна и может хорошо обобщать. Точность проверки очень близка к точности обучения, что указывает на то, что модель изучила временные зависимости без переобучения. Тот факт, что потери обучения и проверки значительно снизились в первые несколько эпох, показывает, насколько хорошо LSTM может улавливать важные временные особенности на ранних этапах обучения.

Результаты. При оценке традиционных и глубокого обучения использовались стандартные показатели эффективности, включающие точность, достоверность, полноту, оценку F1 и матрицы путаницы (Таб.1.6). Random Forest показал наивысшую точность в 62%, а XGBoost достиг 61%. XGBoost продемонстрировал отличную точность в определении событий внезапного торможения (класс 3). Модель SVM продемонстрировала плохую производительность, поскольку достигла только 40% точности и с трудом различала события ускорения и торможения.

Таблица 1.6. Сравнение производительности всех моделей

Модель	Точность	Точность (Макро)	Отзыв (Макро)	F1-оценка (Макро)
LSTM	96%	0,95	0,96	0,96
ГРУ	92%	0,91	0,94	0,92
Си-Эн-Эн	88%	0,88	0,89	0,88

XGBoost	61%	0,63	0,62	0,62
Случайный лес	62%	0,64	0,63	0,64
СВМ	40%	0,48	0,42	0,38

Модели глубокого обучения достигли лучших результатов, чем традиционные методы. Модель LSTM достигла точности 96%, эффективно фиксируя временные зависимости и поддерживая сбалансированную точность и отзыв по всем четырем классам. GRU последовала с точностью 92%, показав силу в обнаружении маневров левого поворота (класс 2). Модель CNN достигла точности 88%, хорошо проявив себя в определении ускорения и торможения, хотя она была менее эффективна в различении поведения при повороте. Подробное сравнение всех моделей приведено в таблице 1, которая подчеркивает превосходную производительность LSTM по всем метрикам оценки. Модель LSTM продемонстрировала наиболее сбалансированные результаты классификации, поскольку она очень редко неправильно классифицировала типы поведения. GRU и CNN продемонстрировали случайные ошибки в идентификации поворотных действий, поскольку сигналы их датчиков перекрывались. Все модели прошли обучение с помощью TensorFlow 2.14 в среде GPU Google Colab, чтобы гарантировать как воспроизводимость, так и скорость вычислений. Более того, XGBoost определил AccX и GyroZ как свои самые важные функции с помощью анализа важности перестановок, который подтвердил их важность для измерения продольного ускорения и углового движения. Столбчатая диаграмма важности функций наглядно продемонстрировала, как эта критическая динамика позволила обнаружить агрессивные маневры, включая внезапное ускорение, торможение и крутые повороты.

3. РАЗРАБОТКА И ОПТИМИЗАЦИЯ АЛГОРИТМОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ РЕАЛИЗАЦИИ СИСТЕМЫ ВИДЕОНАБЛЮДЕНИЯ С ФУНКЦИЕЙ РАСПОЗНАВАНИЯ ЛИЦ

Достижения в области искусственного интеллекта, особенно в области глубокого обучения и машинного зрения, привели к существенному развитию современных технологий видеонаблюдения и безопасности. Разработка систем автоматического распознавания лиц является одной из самых популярных областей на сегодняшний день. Эти системы широко используются в мониторинге общественного порядка, контроле доступа и других областях, требующих высокого уровня безопасности. Тем более отслеживание объектов в реальном времени и распознавание лиц — сложные задачи, требующие сочетания обработки больших данных, различных алгоритмов машинного обучения и сложных методов оптимизации.

Для разработки высокоэффективной системы видеонаблюдения с возможностями распознавания лиц в данном отчете рассматриваются алгоритмы глубокого обучения, где в процессе учитываются также предварительная обработка и дополнение данных, что повышает качество обучения и дает лучшие результаты. Предлагается обзор современных методов распознавания лиц, обнаружения людей, трекинга и их применение в различных отраслях промышленности и сравнение преимуществ и недостатков каждой технологии. Затем рассматривается процесс сбора и подготовки к обучению моделей глубокого обучения, что подразумевает использование большого количества данных и различных методов для их предварительной обработки и дополнения. Более того здесь рассмотрено построение концептуальной, логической и физической модели для эффективного управления данными. Наконец, эти системы складываются в структурные модели системы видеонаблюдения с функцией контроля доступа для эффективного распознавания и отслеживания лиц в реальном времени. Такой подход и разработка чрезвычайно эффективных решений для системы видеонаблюдения дает возможность на улучшение систем безопасности и их удобства использования в

различных областях.

Область распознавания людей, трекинга и распознавания лиц является актуальной. Глобальные тренды в этих областях строятся на продолжающемся развитии высокой точности методов и моделей, удобства и доступности, сопровождаясь значительным вниманием к этическим аспектам.

Такие системы как распознавание лиц имеют широкое применение в умных городах, используются для оптимизации транспортных потоков, мониторинга общественной безопасности и управления инфраструктурой. Использование технологии распознавания людей, трекинга на крупных мероприятиях (спортивные, концерты, фестивали) позволяет идентифицировать людей, отслеживать потоки людей, определяя потенциальные риски. Подобные системы помогают предотвратить столкновение, эффективно управлять потоком людей, следить за безопасностью.

В настоящий момент технологии распознавания лиц активно используются в транспортных хабах, такие как аэропорты, ЖД вокзалы, метро для систем безопасности для быстрой и точной верификации определенных лиц (преступники, без вести пропавшие лица), а в метро города Алматы оплачивать за проезд через верификацию по лицу. Также, такие системы могут быть полезны для анализа поведения посетителей торговых центров, помогая оптимизировать расположение маркетинговых вывесок, расположение торговых островков. В медицинских организациях, имеется возможность верификации по лицу для недопущения использования медицинскими услугами посторонними лицами.

Несмотря на большое количество областей применения подобных технологии, необходимо помнить о сохранении конфиденциальности данных, поскольку системы распознавания лиц фиксируют высокочувствительные биометрические данные, которые при утечке могут быть использованы для целей мошенничества. Чтобы решить эти проблемы, необходимо внедрить строгие меры защиты данных и придерживаться правовых стандартов. Например, при реализации подобных систем в будущем, нам необходимо получение явного согласия от отдельных лиц, когда это возможно, гарантируя, что люди знают, как будут использоваться их биометрические данные. Кроме того, шифрование данных, применение методов анонимизации и безопасные методы хранения имеют жизненно важное значение для предотвращения несанкционированного доступа и нарушений.

Несмотря на то, что тема данного подпроекта касается задач связанных с распознаванием лиц, невозможно рассматривать ее изолированно, так как для полного функционирования таких систем необходимо учитывать также задачи связанные для идентификацией, распознаванием людей, отслеживания их перемещений. Распознавание лиц отвечает за идентификацию конкретных людей, однако для успешной работы подобных систем необходимо дополнительные компоненты для распознавания людей и трекинга, чтобы система смогла понимать контекст сцены, отслеживать движения объектов, предсказывать траекторию.

Следующие части данного исследования будут содержать введение в методы определения людей, трекинга, распознавания лиц, методы предобработки/аугментации данных для распознавания лиц, людей, приложения (возможные сценарии) использования подобных систем, структурная модель сбора, хранения данных на примере потенциального решения для автобусного парка г.Астаны, а также решения для контроля доступа в домах студентов Astana IT University.

Данное исследование было сосредоточено в первую очередь на обзоре методов предварительной обработки изображений, извлечении признаков, аугментации данных, а также современных методов машинного обучения (ML) и глубокого обучения (DL) с их применением в задачах обнаружения, отслеживания и идентификации человека, распознавания лиц.

3.1. Методы определения людей, трекинга и распознавания лиц

3.1.1 Обнаружение людей

Одной из важнейших задач в компьютерном зрении является обнаружение человека, точнее обнаружение и идентификация людей на изображениях или видеопотоках. Обнаружение человека, как правило, является подмножеством проблемы обнаружения объекта с ограничением обнаружения человеческих фигур. Человекоподобные объекты выделяются и отделяются от фона, будучи окруженными прямоугольной рамкой. Все модели обнаружения объектов делятся на две категории по типу обнаружения: - одноступенчатые и двухступенчатые модели. Модели двухступенчатой архитектуры разделяют задачу классификации объекта от задачи определения местоположения объекта и перед

классификацией области генерируют предложение области [80]. Эти модели были первыми в глубоких сверточных нейронных сетях, которые показали высокую точность обнаружения, но с медленной скоростью обнаружения. С развитием технологий и новыми большими наборами данных были введены одноступенчатые DCCN. Их основным преимуществом была скорость обработки в реальном времени, но они менее точны, особенно для небольших объектов на изображениях с низким разрешением [81]. Помимо скорости обнаружения и мелких объектов, мы можем столкнуться с другими проблемами, такими как плотная окклюзия, когда модель часто приводит к пропущенным и ложным обнаружениям, как при обнаружении пешеходов, особенно когда объекты одной и той же или разных категорий закрывают друг друга [80]. Также иерархическая структура сверточных нейронных сетей затрудняет обнаружение объектов с несколькими масштабами.


Существует другой метод, который предоставляет гораздо более подробную информацию за счет более высокой вычислительной сложности, а именно обнаружение путем сегментации. В отличие от обнаружения объектов, которое использует ограничивающие рамки для определения местоположения людей, сегментация обеспечивает точность на уровне пикселей, описывая точную форму и контуры людей. Общую сегментацию можно разделить на три основных типа: сегментация экземпляров, семантическая сегментация и паноптическая сегментация [82]. Сегментация экземпляров в основном фокусируется на создании масок вокруг каждого объекта для распознавания и различения отдельных объектов на изображении, тогда как семантическая сегментация назначает метку класса каждому пикселю на изображении, собирая все пиксели одного класса под единой меткой. Например, при обнаружении человека сегментация экземпляров может маскировать уникальные цветные маски для каждого человека, чтобы избежать путаницы, а семантическая сегментация может маркировать все пиксели, принадлежащие людям, одним цветом. Эти два метода объединены в паноптической сегментации, предоставляя четкие границы объектов и попиксельные метки одновременно. Технологии сегментации быстро развиваются с развитием глубокого обучения и вычислительной мощности, что делает обнаружение человека более точным в сложных условиях. В недавнем исследовании авторы предложили высокоэффективную систему сегментации человека, которая значительно повышает точность

сегментации при использовании гораздо меньшей сети CNN [83]. В другом исследовании авторы предложили новую архитектуру на основе MobileNetV3m, которая сегментирует людей на изображениях и видео со скоростью 35 кадров в секунду на Google Pixel 4 [84]. Даже с улучшениями в сегментации для обнаружения людей, все еще есть ряд важных проблем, похожих на обнаружение объектов, таких как окклюзия в людных местах и изменчивость внешнего вида, вызванная такими вещами, как одежда и освещение. Кроме того, многие исследования не воспроизводимы, поскольку они часто сообщают результаты на нестандартных наборах данных или не указывают четко свои экспериментальные установки.

Последний метод, который подходит для задачи обнаружения людей, — это оценка позы. Оценка позы играет заметную роль в CV и расширяет концепции обнаружения людей, сосредоточившись на точном определении и локализации ключевых точек. В то время как обнаружение человека включает в себя распознавание людей в сцене, а сегментация направлена на определение их форм, оценка позы идет на шаг дальше, отображая точное положение суставов и конечностей, что позволяет детально понять позу и движение человека. Оценка позы разделена на 2 части — 2D и 3D оценку позы, где разница заключается в том, локализованы ли ключевые точки в двухмерном пространстве или в трехмерном пространстве. Хотя оценка позы человека значительно продвинулась вперед, все еще существуют проблемы, особенно при работе со сложными фонами и различными масштабами человека. Большое значение придавалось таким архитектурам, как OpenPose, которые различают как большие, так и маленькие ключевые точки [85]. Такие фреймворки, как UniPose+, используют многомасштабные представления признаков и обеспечивают точную 2D и 3D оценку позы без увеличения вычислительной сложности [86]. Примеры всех методов приведены в Рисунке 3.1.



(а) Определение объектов



(b) Сегментация



(с) Определение позы

Рисунок 3.1 – Пример обнаружения объектов, сегментации объектов и оценки позы человека [87]

Хотя такие концепции, как предварительная обработка изображений, извлечение признаков и классификация, могут использоваться для решения этих задач в качестве автономных решений [88], некоторые из них уже являются частью более сложных и современных моделей. В качестве примера можно указать на модель обнаружения объектов YOLO (You Only Look Once) [89]

с интегрированными внутренними частями. В третьей версии YOLO разработчики составили часть извлечения признаков с 53 сверточными слоями, которая стала масштабной архитектурой извлечения признаков и, несомненно, одним из важных шагов в обнаружении объектов.

3.1.2. Отслеживание людей

Отслеживание людей подразумевает непрерывное слежение за объектом в видеопотоке с камер видеонаблюдения. Эта проблема расширяет возможности моделей обнаружения объектов, не только определяя ограничивающие рамки вокруг людей, но и связывая обнаружения из одного кадра с другим. Доступные нам системы, такие как отслеживание нескольких объектов (MOT), обычно включают этап обнаружения, на котором определяются цели в отдельных видеокдрах, и этап ассоциации, на котором идентифицированные цели связываются с их траекториями [90]. В дополнение к этому предлагаются функции отслеживания нескольких объектов в реальном времени, которые могут использоваться в качестве систем наблюдения. Пример алгоритма отслеживания нескольких объектов в реальном времени, предложенного в [91], представляет собой комбинацию высокоскоростных обнаружений из фреймворка YOLO с глубоким извлечением признаков из сверточной нейронной сети (CNN). Исследования по отслеживанию людей бросают вызов долгосрочным окклюзиям и различению похожих людей, что каждый раз повышает точность моделей [92]. Поэтому надежность систем отслеживания в суровых условиях и интеграция многомодальных данных, таких как данные с датчиков глубины и температуры, остаются значительными исследовательскими пробелами в этой области.

3.1.3 Идентификация человека

Идентификация человека — это еще одна задача компьютерного зрения, которая направлена на сопоставление личности человека в заданном кадре с информацией базы данных. В отличие от отслеживания человека, которое фокусируется на постоянном слежении за человеком в пределах сцены, идентификация человека включает в себя точное сопоставление существования человека. Идентификация человека распространяется на более

сложную задачу — повторную идентификацию человека (Re-ID), которая включает в себя идентификацию по нескольким камерам или местам в последовательности видео или изображений. Эти системы можно разделить на две основные категории: закрытый мир и открытый мир [93]. Повторная идентификация человека (Re-ID) добилась значительного успеха в условиях закрытого мира с помощью методов глубокого обучения, сосредоточенных на метрическом обучении, глубоком представлении признаков и оптимизации ранжирования. Однако по мере насыщения производительности исследования перешли в более сложную среду открытого мира, где различия в одежде, окружении и скрытые личности создают больше трудностей, характерных для приложений реального мира. Те же проблемы по-прежнему сохраняются, включая обработку экстремальных изменений во внешнем виде из-за окклюзии, освещения или смены одежды. Существуют также пробелы в исследованиях в разработке более надежных алгоритмов, которые могут адаптироваться к новым идентификациям в режиме реального времени и интегрировать многомодальные данные с разных типов камер.

3.1.4 Распознавание лиц

Распознавание лиц стало важнейшей технологией с широким спектром приложений: от безопасности и наблюдения до идентификации и аутентификации личности. В последние годы в этой области наблюдаются значительные достижения, обусловленные разработкой мощных алгоритмов машинного обучения, доступностью крупномасштабных наборов данных о лицах и растущей вычислительной мощностью современных вычислительных систем [94]. Однако, несмотря на значительный прогресс, остается ряд проблем и ограничений, особенно с точки зрения надежности, справедливости и обобщения в различных условиях.

Распознавание лиц включает несколько этапов от захвата изображения до окончательной идентификации лица: захват изображения, предварительная обработка, обнаружение лица, выравнивание лица, извлечение признаков, сравнение и идентификация. На каждом этапе используются свои собственные методы, модели и алгоритмы. Например, после захвата изображения с камеры или статической фотографии оно проходит предварительную обработку для улучшения его качества и подготовки к распознаванию.

Затем классические методы, такие как каскады Хаара [95] или гистограмма ориентированных градиентов [96] или современные модели на основе CNN (сверточных нейронных сетей), такие как MTCNN [97], используются для обнаружения и выделения лица на изображении. Выравнивание лица может быть достигнуто с помощью методов, которые используют ориентиры лица, которые позволяют правильно позиционировать лицо относительно оси изображения [98]. После обнаружения и выравнивания лица извлекаются признаки, которые описывают уникальные характеристики лица. Опять же, извлечение признаков может быть выполнено с использованием классических методов, которые анализируют текстуру лица и его геометрические особенности, такие как LBP (локальные бинарные шаблоны) [99] или SIFT (масштабно-инвариантное преобразование признаков) [100], а также с использованием глубоких нейронных сетей, таких как FaceNet или VGG-Face, которые могут извлекать более сложные и глубокие особенности, создавая компактное векторное представление лица — встраивание [101].

Традиционные системы распознавания лиц требуют больших наборов данных для обучения. Однако во многих реальных приложениях получение огромных объемов маркированных данных о лицах нецелесообразно. Для решения этой проблемы стали популярны методы обучения с одним и несколькими выстрелами, такие как Siamese Networks и Matching Networks. Эти подходы направлены на распознавание лиц на основе одного или очень немногих примеров [102], что делает их более применимыми в наблюдении и биометрической идентификации. Точное распознавание лиц часто зависит от точного обнаружения и выравнивания ориентиров лица. Такие методы, как Dlib и OpenFace, определяют ключевые точки на лице (например, глаза, нос и рот) для выравнивания изображений лица, уменьшая вариации, вызванные позой, освещением или выражением [103]. Эти методы повышают точность распознавания за счет стандартизации входных данных перед их подачей в нейронную сеть. Глубокое обучение таиз-за его способности автоматически изучать представления признаков из больших наборов данных. Основными вехами являются появление таких моделей как - DeepFace (2014), FaceNet (2015), VGG-Face (2015), ArcFace (2019). Главной особенностью появившихся моделей глубокого обучения для распознавания лиц стало использование подходов, которые автоматически извлекают и

оптимизируют дискриминационные представления лиц, обеспечивая высокую точность за счет глубоких архитектур и специализированных функций потерь.

Одной из основных недостатков систем распознавания лиц является обработка изменений в позе, освещении и выражении лица. Хотя модели глубокого обучения достигли значительных успехов в решении этих факторов, экстремальные условия (например, боковые профили, слабое освещение) по-прежнему создают трудности [104]. Для смягчения этих проблем изучаются такие подходы, как 3D-моделирование лиц и распознавание лиц, не зависящее от позы.

Многие наборы данных распознавания лиц смещены в сторону определенных демографических групп, особенно с точки зрения расы, пола и возраста. Исследования показали, что системы распознавания лиц, как правило, лучше работают на людях со светлой кожей и мужчинах, что вызывает опасения по поводу справедливости и потенциального неправомерного использования [105]. Для решения этих этических проблем разрабатываются такие решения, как обучение на основе справедливого представления и методы устранения предвзятости.

Системы распознавания лиц уязвимы для состязательных атак, когда небольшие возмущения изображения могут ввести модель в заблуждение и заставить ее делать неверные прогнозы. Кроме того, атаки с подменой, такие как предоставление фотографий или масок системе, представляют собой риски безопасности. Механизмы защиты от соперничества и методы обнаружения жизнееспособности (например, обнаружение моргания, сердцебиения или анализ текстуры) являются активными областями исследований, направленных на повышение надежности этих систем [106]. Широкое внедрение систем распознавания лиц также вызывает этические и правовые вопросы, связанные с правом на частную жизнь, согласие на сбор данных и потенциальное использование этой технологии для наблюдения и контроля.

Хотя модели распознавания лиц хорошо работают на определенных наборах данных (например, LFW, MegaFace), их способность обобщать невидимые наборы данных часто ограничена. Обобщение между наборами данных остается открытой проблемой, поскольку многие модели переобучаются для особенностей обучающих наборов данных и испытывают трудности при столкновении с новыми условиями или новыми людьми [107].

Решения могут включать методы адаптации домена и метаобучение для улучшения производительности между доменами.

С ростом развертывания распознавания лиц в общественных и частных пространствах растут проблемы конфиденциальности. Традиционные системы распознавания лиц полагаются на централизованные базы данных, где хранятся вставки лиц, что делает их уязвимыми для утечек данных. Исследования в области распознавания лиц с сохранением конфиденциальности с использованием таких методов, как федеративное обучение и гомоморфное шифрование, имеют важное значение для защиты пользовательских данных при сохранении полезности системы [108].

Распознавание лиц в реальном времени в крупномасштабных системах, таких как те, которые используются в аэропортах или умных городах, требует эффективных и масштабируемых решений. Современные современные модели могут быть вычислительно затратными, что ограничивает их развертывание в средах с ограниченными ресурсами. Методы сжатия моделей (например, квантование, обрезка) и аппаратные ускорители (например, графические процессоры, TPU) изучаются для уменьшения задержки и увеличения пропускной способности [109]. Внешний вид лица значительно меняется со временем из-за старения, что создает проблемы для долгосрочных систем распознавания лиц. Хотя существуют некоторые модели распознавания лиц, не зависящие от старения, они далеки от совершенства. Для решения этой проблемы изучаются методы моделирования прогрессии возраста и временной адаптации [110].

Некоторые системы распознавания лиц начали использовать мультимодальные данные, такие как объединение данных о лицах с голосовыми или поведенческими биометрическими данными, чтобы повысить точность. Мультимодальная аутентификация может улучшить надежность систем, но также добавляет новые проблемы, связанные с синхронизацией и обработкой различных типов данных, что требует разработки эффективных методов интеграции мультимодальных данных.

3.2 Приложения методов машинного обучения для распознавания лиц, определения объектов и их трекинга

На сегодняшний день практические применения в области распознавания лиц, определения объектов и их трекинга очень

широко распространены. А именно можно привести пример использования таких технологий в городских условиях как и с большим скоплением людей, также для индивидуального распознавания и трекинга. Зачастую такие системы устанавливают местные власти, но не исключены применения таких решений отдельными частными лицами в своих интересах. Системы могут использоваться для аналитических действий и для общей безопасности. Тем не менее по мере развития компьютерного зрения есть отдельные применения в точечных областях, таких как транспортная область, где власти имеют возможность не только обеспечить общественную безопасность в автобусах а также управлять пассажиропотоком для эффективного управления городской системы.

Подсчет толпы — важная задача в компьютерном зрении, имеющая многочисленные приложения в общественной безопасности, управлении мероприятиями, городском планировании и распределении ресурсов. Она подразумевает точную оценку количества людей на изображении, которое часто фиксируется в сложных и густонаселенных сценах. В статье [111] исследователи предложили систему IoT с камерами наблюдения, которая будет собирать видеоданные для предварительно обученной модели. В их архитектуре камеры должны находиться в обозначенных общественных местах, каждой из которых будет присвоен IP-адрес. После этого камеры будут связаны с облаком через технологию Wi-Fi. Следующий шаг включает подключение устройства пользователя к облаку. Затем данные отправляются из облака с использованием обучающей модели DCNN для первичного запуска системы подсчета толпы после доступа к данным из облака на устройства конечных пользователей через Интернет. Затем будут собраны необходимые обработанные данные. Наконец, результат будет передан и отображен в мобильном приложении пользователя.

Современные системы конфиденциальности и безопасности в значительной степени полагаются на технологии обнаружения и идентификации человека, которые используют технологические прорывы в области обнаружения, идентификации и отслеживания человека для улучшения мониторинга, контроля доступа и наблюдения. Одно исследование показывает, как глубокое обучение в области наблюдения может обнаруживать злоумышленников и домовладельцев [112]. С помощью MobileNets для распознавания фигур и EfficientDet для обнаружения объектов эта система

может распознавать людей на видео и классифицировать их как домовладельца или неопознанного человека. Владелец дома получит уведомление, если будет обнаружен злоумышленник, а также краткую видеозапись инцидента, которую можно просмотреть через веб-приложение.

Система обнаружения и наблюдения за вторжением Smart Intruder Detection and Surveillance System (SIDSS), система безопасности дома, предложенная в этом [113] исследовании, использует алгоритмы компьютерного зрения для идентификации и категоризации вторжений с исчерпывающей информацией об угрозах, такой как виды нарушителей и оружие. SIDSS состоит из трех шагов: главный компонентный анализ (PCA) для обучения распознавателя лиц для различения нарушителей от наблюдателей; каскадные классификаторы с механизмом коррекции для устранения пропущенных угроз; и оптимизированная сверточная нейронная сеть для обнаружения угроз и вторжений (Рис.3.2).




Рисунок 3.2 – Схема нейронной сети для обнаружения нарушителей Smart Intruder Detection and Surveillance System (SIDSS) [114]

Технологии обнаружения и идентификации людей являются важнейшими компонентами интеллектуальных городских и транспортных систем, улучшая управление дорожным движением и общественную безопасность. Власти могут отслеживать людей по нескольким камерам в общественном транспорте благодаря таким методам, как повторная идентификация, которая повышает их способность обнаруживать подозрительную активность и улучшать управление пассажирами в транспорте. В статье [115] представлена усовершенствованная архитектура для системы мониторинга на основе камер, разработанной для интеллектуальных городских дорог, в частности, с использованием обнаружения и отслеживания людей. Основной конвейер начинается с программного обеспечения Nvidia DeepStream, позволяющего развертывать модель обнаружения в реальном времени по всем камерам, установленным в городе. Эта модель идентифицирует людей и объекты, такие как транспортные средства, а затем генерирует несколько потоков данных для параллельной обработки. Kafka реализован как брокер сообщений для минимизации задержки между выходными данными в реальном времени и аналитической обработкой, гарантируя бесперебойную передачу данных в подключенные приложения. Grafana затем извлекает эти данные с сервера Kafka, используя их для создания живой интерактивной панели, которая визуализирует аналитику, сгенерированную системой, например, показатели плотности пешеходов и транспортных средств. Эта интегрированная архитектура обеспечивает мониторинг в реальном времени, что делает ее очень подходящей для управления движением и пешеходами в городских районах.

3.2. Исследование и разработка структурной модели сбора и подготовки больших данных для машинного и глубокого обучения

3.2.1. Модель сбора и подготовки большого объема данных для обучения глубоких нейронных сетей

Модель сбора и подготовки данных для обучения глубоких нейронных сетей включает несколько ключевых этапов, начиная с формирования стратегии сбора и проверки качества данных. В контексте задач распознавания лиц источниками данных могут выступать как открытые датасеты, так и данные, полученные в

рамках специализированных сборов — например, с камер видеонаблюдения или с публичных интернет-ресурсов. Среди наиболее известных и часто используемых наборов данных для распознавания лиц можно выделить: Labeled Faces in the Wild [116] - около 13 000 изображений лиц знаменитостей в разных условиях; VGGFace и VGGFace2 [117] - разнообразные изображения с вариациями поз, возраста и освещения; MS-Celeb-1M - более миллиона изображений знаменитостей; CASIA-WebFace — свыше 500 000 изображений для задач распознавания и верификации; CelebA — данные с аннотациями атрибутов лица; WIDER Face — сложные сцены для детекции лиц. Как можно заметить, эти датасеты включают изображения различных людей в различных условиях и позах, что позволяет моделям обучаться распознавать лица при изменении освещения, угла съемки и других факторов, приближая задачи к реальным условиям. Ключевым моментом в сборе данных является обеспечение разнообразия и объема. Важно, чтобы данные охватывали множество лиц с различными особенностями — разными выражениями, прическами, и аксессуарами, такими как очки. Это помогает модели лучше обобщать полученные знания и применять их к новым данным.

Однако, чтобы понять, что данные действительно подходят для обучения, необходимо учитывать несколько факторов: данные должны быть равномерно распределены по классам (если это классификационная задача), а сами изображения должны быть достаточно высокого разрешения для извлечения важных характеристик.

В контексте сбора, хранения и обработки данных для задач распознавания лиц, построение концептуальной, логической и физической модели данных помогают систематизировать, оптимизировать и эффективно управлять данными на каждом этапе работы системы:

1. Концептуальная модель данных. Источниками данных для задач распознавания лиц служат разнообразные датасеты, такие как LFW, VGGFace2, MS-Celeb-1M, а также специализированные коллекции изображений и видео с видеокamer и других устройств. Сбор данных включает в себя получение изображений и видеозаписей с лицами из различных источников, а также проведение первичной фильтрации для отбора качественных данных. На этапе предобработки данные проходят нормализацию: выполняется выравнивание лиц, масштабирование, приведение изображений к

единому размеру, нормализация цветовой гаммы и удаление шумов. Эти шаги (Рис 3.3) позволяют подготовить данные для дальнейшего анализа и улучшить качество распознавания лиц.




Рисунок 3.3 - Основные этапы концептуальной модели

2. Логическая модель данных. Компоненты логической модели включают в себя следующие модули: модуль сбора данных (Data Ingestion Module), отвечающий за извлечение и агрегацию изображений из различных источников, включая веб-страницы, базы данных и видеопотоки; модуль предобработки данных (Data Pre-processing Module), который выполняет выравнивание лиц, изменение размера изображений, нормализацию и другие обработки для унификации данных; платформу аннотации (Annotation Platform), предназначенную для маркировки лиц на изображениях и включающую API для автоматического распознавания или интерфейсы для ручной аннотации. Центральное хранилище данных (Data Repository) служит для хранения изображений и аннотаций и обеспечивает быстрый доступ к данным при необходимости. Модуль контроля качества (Quality Control) проверяет качество данных, включая наличие шумов, четкость изображений

и другие параметры. Система обучения модели (Model Training System) использует подготовленные и аннотированные данные для обучения модели распознавания лиц (Рис.3.4).




Рисунок 3.4 - Основные компоненты логической модели

3. Физическая модель данных. Компоненты физической модели включают серверы для сбора данных, которые используют скрипты на Python или API для автоматизированного сбора данных, например, с веб-страниц или видеопотоков. Для хранения изображений и метаданных служат физическое хранилище в здании и базы данных, где локальный сервер обеспечивает хранение изображений, а PostgreSQL используется для хранения метаданных и аннотаций. Кластеры для предобработки данных включают серверы с GPU, которые ускоряют обработку изображений, например, выравнивание лиц, нормализацию и аугментацию. Система аннотаций представляет собой веб-приложение или API, предназначенные для аннотирования данных. Для мониторинга качества данных используются скрипты и программы на основе OpenCV или других библиотек для проверки четкости, разрешения и корректности данных. Платформа обучения включает локальные серверы с GPU, которые используются для обучения модели и интегрированы с системой хранения данных (Рис.3.5).




Рисунок 3.5 - Основные компоненты физической модели

Управление и организация данных для последующего использования

Эффективное управление данными предполагает использование таких систем, как:

- Системы управления версиями данных, например Delta Lake или DVC (пример системы показан на Рис.3.6), чтобы отслеживать изменения и версионирование данных, что особенно важно для аудита и обновления моделей.

- Автоматизация обновлений данных: для своевременного обновления данных и поддержания актуальности базы лиц можно интегрировать системы, такие как Apache NiFi или Airflow, которые автоматизируют процесс обновления и обеспечивают интеграцию данных с системой аналитики.

Для контроля за выполнением всех требований по обновлению и дообучению моделей, очень популярным является применение парадигмы MLOps, которая предусматривает своевременное обновление моделей за счет переобучения и загрузки новых версий с применением постоянно обновляемых данных.




Рисунок 3.6. Пример системы управления и организации данных с использованием DVC

Метрики качества и оценка данных

Качество набора данных оценивается с использованием объективных метрик, которые позволяют контролировать пригодность изображений для обучения моделей. Одной из таких метрик является резкость и фокусировка, которая позволяет отслеживать степень размытости изображений, что особенно важно для распознавания мелких деталей лица. Еще одной ключевой метрикой является освещенность: равномерное освещение помогает избежать искажений изображения и улучшает качество данных. Кроме того, оценивается полнота данных, то есть наличие всех ключевых точек лица на каждом кадре, что проверяется с помощью алгоритмов детекции ключевых точек. Периодическая оценка данных на основе этих метрик позволяет своевременно выявлять проблемы и корректировать параметры сбора данных, обеспечивая стабильное качество набора данных для обучения.

3.2.2. Предобработка данных для распознавания лиц, людей

Предобработка данных для распознавания лиц и идентификации людей является важным этапом, который позволяет улучшить качество модели, подготовить данные к обучению и сделать

модель более устойчивой к различным условиям. Этот процесс включает несколько шагов:

1. Выравнивание лиц: Одним из ключевых шагов является выравнивание лиц на основе ключевых точек, таких как глаза, нос и уголки рта. Выравнивание (или нормализация по позе) помогает уменьшить различия, связанные с поворотами и наклонами головы. Например, если изображения были получены под разными углами, модель может испытывать трудности с правильной идентификацией, но выравнивание устраняет такие несоответствия, улучшая точность (Рис.3.7). Например, алгоритмы, такие как MTCNN или RetinaFace, могут автоматически распознавать ключевые точки лица и скорректировать ориентацию изображения, подготавливая его для последующей обработки.



Рисунок 3.7. Пример выравнивания лица (face alignment)

2. Приведение к единому размеру и формату: Для работы большинства моделей, таких как CNN или трансформеры, изображения приводят к единому размеру (например, 224x224 или 128x128 пикселей). Это упрощает обучение, поскольку модель всегда получает входные данные одинакового размера. В нашем примере мы использовали данные с камеры видеонаблюдения с фермы в Алматинской области, функции приведения изображения к стандарту схожим несмотря на сцену и объекты в сцене. Также изображения могут конвертироваться в черно-белый формат, если задача не требует анализа цветовых особенностей. Это может быть полезно, если цветовая информация не влияет на распознавание, что уменьшает размер данных и ускоряет обучение.

3. Нормализация цветовой гаммы: Лица на изображениях могут иметь разные освещение, цветовой тон и контрастность. Чтобы минимизировать эти различия, используется нормализация цветовой гаммы, выравнивая значения пикселей. Например,

модели часто обучаются с использованием нормализованных значений, выведенных из ImageNet или другого стандарта. Этот процесс уменьшает влияние различий освещения и повышает устойчивость модели к изменениям условий съемки.

4. Удаление шума и повышение резкости: Изображения, полученные в условиях плохого освещения или на старых устройствах, могут содержать шум. Используются фильтры для удаления шумов и повышения резкости, что помогает улучшить четкость черт лица. Например, для уменьшения размытия применяют фильтры повышения резкости, а для удаления цифрового шума — гауссовы фильтры. Улучшение качества данных включает использование различных техник, направленных на повышение их пригодности для обучения моделей. Одной из таких техник является фильтрация данных, которая предполагает исключение размытых или плохо освещенных изображений. Это позволяет улучшить результаты обучения, так как модель обучается на более качественных примерах. Для реализации фильтрации можно использовать метрики качества, такие как анализ резкости (например, метод Laplacian Variance), позволяющий автоматически оценивать четкость изображений. Еще одним важным подходом является контроль качества данных, который может включать как автоматические метрики, так и периодические ручные проверки. Автоматический контроль качества помогает в реальном времени анализировать параметры изображений, такие как резкость, яркость и контрастность, обеспечивая стабильность и высокое качество обучающего набора.

5. Увеличение данных: Если доступных изображений недостаточно, используются методы увеличения данных, чтобы получить больше примеров для обучения. Например, можно создавать дополнительные изображения с использованием различных аугментаций. Этот подход помогает модели лучше справляться с недостатком данных и улучшает её устойчивость к различным факторам.

6. Извлечение ключевых признаков: В некоторых случаях, особенно при подготовке к обучению классических моделей, можно предварительно выделить ключевые признаки лица, такие как контуры глаз, бровей, губ и т. д. Это позволяет уменьшить размер данных и обучить модель распознавать только те части, которые наиболее информативны для идентификации.

7. Контроль качества данных: На финальном

этапе предобработки проводится оценка качества изображений. Убедившись, что все изображения соответствуют стандартам качества и не содержат значительных искажений, можно снизить вероятность появления ошибок в обучении модели. Изображения с низким качеством или серьезными искажениями, которые не поддаются коррекции, могут быть исключены, чтобы повысить общее качество данных. Для обучения нейронной сети видео материалы должны включать в себя только кадры с нужным ему объектом. Видео данные CTS имеют ненужные кадры где людей нет. В рамках предобработки выделяются кадры, содержащие людей, и удаляются ненужные фрагменты.

3.2.3 Аугментация данных для глубокого обучения

В сфере глубокого обучения аугментация данных играет важную роль как для тренировки модели, так и для предотвращения проблемы переобучения. Аугментация данных — это процесс, позволяющий расширить информацию, извлекаемую из имеющегося датасета, за счет искусственного увеличения его объема [118]. Данный метод позволяет повысить точность и качество работы модели [119]. Основные методы аугментации данных в области компьютерного зрения включают:

- Геометрические операции: применение различных геометрических преобразований изображений, таких как повороты, обрезка, зеркальное отображение (flipping), сдвиг, уменьшение шума изображения.
- Цветовые преобразования: изменение цветовых характеристик изображения, например, перевод изображения из RGB в градации серого, увеличение или уменьшение яркости, контрастности и насыщенности пикселей.
- Фильтрация: использование фильтров, например, гауссовских, для размытия или повышения резкости изображения.
- Скрытие объектов: удаление или размывание ненужных частей изображения путем маскирования определенных областей пикселей.
- Mixup: метод, основанный на объединении двух изображений с использованием линейной интерполяции для создания нового варианта изображения.
- Продвинутые методы: включают использование GANs, AugMix, StyleGAN и других моделей, которые создают более

сложные и разнообразные преобразования данных. Например, Philip Wang создал сервис генерации лиц на базе GAN, который можно протестировать на сайте <https://thispersondoesnotexist.com>. Для этого можно использовать библиотеки, такие как Augmentor или Albumentations, позволяющие настроить параметры аугментации под конкретные условия задачи распознавания лиц.

Эти методы можно также комбинировать, создавая более разнообразные и уникальные варианты данных для улучшения работы модели (Рис.3.8).




Рисунок 3.8. Пример аугментации данных на датасете CTS. а) Применение цветowych преобразований пикселей, б) Использование Гауссовских преобразований, в) Применение геометрических преобразований, г) Аугментация данных путем случайного удаления областей изображения.

В нашей задаче аугментация данных потребуется для компенсации недостатка обработанных данных. Для каждого изображения

будет случайным образом применено по три основных метода, таких как: поворот изображений на 45 градусов влево и вправо, изменение яркости, отражение или добавление небольших шумов с использованием функции Гаусса. Это позволит увеличить количество данных в 3 раза и улучшить устойчивость модели, помогая справиться с проблемой переобучения. Аугментация будет выполняться с использованием Python-библиотек, таких как OpenCV, DeepLib и NumPy.

3.2.4. Структурная модель системы для контроля доступа и распознавания пассажиров

Система контроля доступа.

Архитектуру системы контроля доступа установленного в общежитии для студентов в Astana IT University, включает в себя несколько компонентов для обработки и анализа данных. Система состоит из фронтенда, бэкенда и аналитического модуля. Для обмена данными используется REST API (POST, GET, PUT, DELETE). Аналитический модуль обрабатывает видеопоток полученный с камеры, формирует результаты. Все данные включая результаты аналитики, хранятся в реляционной базе данных PostgreSQL; Redis-кэш используется для ускорения доступа к данным; файловое хранилище — для долговременного хранения данных и объектов, распознанных в кадрах.




Рисунок 3.9 - Архитектура системы контроля доступа

Концептуальная модель системы включает основные сущности (например, лицо, кадр, событие), их свойства и взаимосвязи. В модели имеются следующие сущности - пользователи (атрибуты: ID, имя, роль, контакты), объекты мониторинга (атрибуты: ID, название, адрес, список камер), камеры (атрибуты: ID, объект, RTSP-ссылка, статус работы), лица, метаданные аналитики (атрибуты: ID, камера, время фиксации, статус проверки, метка совпадения) и связи между ними.

Схема концептуальной модели базы данных для системы контроля доступа с распознаванием лиц выглядеть как на Рис.3.10.




Рисунок 3.10 - Схема концептуальной модели базы данных

Логическая модель уточняет атрибуты данных и их связи, определяя ключевые характеристики, такие как идентификаторы, временные метки и другие параметры, связанные с процессом обработки и хранения данных.

- Построение диаграмм ERD (Entity Relationship Diagram) для отражения ключевых полей и связей, таких как связи «один ко многим» (например, один объект имеет много камер) .

- Определение типов данных для каждого атрибута и

уточнение обязательных и необязательных полей.

- Разработка ограничений для ключей и ссылок, чтобы избежать ошибок при внесении данных и сохранить целостность данных. Пример логической модели данных для системы распознавания лиц приведены на Рис. 3.11.




Рисунок 3.11 - Пример логической модели для системы распознавания лиц

Физическая модель (Рис.3.12-3.16) определяет конкретные технические аспекты хранения данных, такие как использование распределенных баз данных и индексации для оптимизации быстрого доступа.

- Разработка схемы базы данных с учетом требований к производительности.

- Определение индексов на ключевых полях для ускорения запросов (например, на поле идентификатора лица или времени фиксации метаданных).

- Настройка резервного копирования и восстановления данных для обеспечения надежности.

Основная модель данных, CameraModel (Рис.3.12) включает следующие поля: идентификатор, серийный номер, название бренда, модель камеры, дату регистрации, статус активности и

URL. Связь между камерами и общежитиями представлена через модель DormModel, в которой указывается идентификатор камеры и организации. REST API состоит из следующих эндпоинтов: создание, получение списка, обновление, удаление, активацию и деактивацию камер.




Рисунок 3.12 - API для управления камерами в системе

Основная модель StudentModel (Рис.3.13) содержит информацию о студентах: идентификатор, имя, фамилия, номер id_card, статус активности, пол, дата рождения, путь к фотографии и идентификатор общежития.

API эндпоинты: получение списка студентов, создание, удаление, обновление и получение данных по идентификатору. Также доступен эндпоинт для пакетного добавления студентов с использованием Excel-файла и загрузки фотографий.




Рисунок 3.13 - REST API для управления данными студентов.

Основная модель OrganizationModel (Рис.3.14) содержит информацию об организациях: идентификатор, наименование, имя CEO, адрес, телефон.

API эндпоинты: получение списка организаций, создание, удаление, обновление и получение данных по идентификатору.




Рисунок 3.14 - REST API для управления организациями.

Основная модель `OrganizationModel` (Рис.3.15) содержит информацию о сотрудниках и ролях: идентификатор, имя, фамилия, `id_card`, флаг активности, роль, логин, пароль, идентификатор организации.

`RolesEnum` содержит типы сотрудников: Системный администратор(`super_admin`), Администратор(`admin`), Регистратор(`registrar`), Оператор(`operator`). API эндпоинты:

получение списка сотрудников, создание, удаление, обновление и получение данных по идентификатору.




Рисунок 3.15 - REST API для управления сотрудниками

Основная модель DormModel (Рис.3.16) содержит информацию о общежитиях: идентификатор, идентификатор организации, наименование, адрес, идентификатор камеры.

API эндпоинты: получение списка общежитий, создание, удаление, обновление и получение данных по идентификатору.




Рисунок 3.16 - REST API для управления общежитиями

ЗАКЛЮЧЕНИЕ

В результате сравнительного анализа и литературного обзора обнаружено, что на сегодняшний день доступно очень мало эмпирических данных, демонстрирующих социально-экономические, культурные и другие аспекты внедрения каршеринга в стране. Это может служить направлением для будущей работы по данной теме. А именно, исследования с помощью интервью фокус-групп, с акцентом на сбор данных у всех участников процесса, включая компании, предоставляющие услуги по каршеринг, потенциальные и текущие пользователи каршеринг, государственные органы могут улучшить понимание текущего состояния сервиса в Казахстане и предоставить более глубокое понимание того, какие шаги могут быть предприняты для улучшения данного вида мобильности. Таким образом, проведение исследований в данном направлении, с глубоким анализом полученных данных является приоритетной работой в будущем. На основе таких данных государственные органы могут разработать нормативно-правовые документы, регулирующие деятельность поставщиков услуг, что в свою очередь может помочь компаниям лучше организовать свою работу. Особенно, учитывая, что в Казахстане на данный момент действует только одна компания, предоставляющая прямые услуги по каршеринг данный вопрос является актуальным. Ведь рынок является привлекательным для частного бизнеса и при должном регулировании и поддержки со стороны государства может стать значительным драйвером развития экономики. Следует также учитывать стремительное развитие информационных-технологий, которое должно найти свое отражение и в услугах каршеринг. Предоставляя современные технические решения для своих пользователей (мобильные приложения и веб-сайты), как в случае с *anytime* и другими зарубежными аналогами (*Turo*, *ZipCar*, *Car2Go*), компании могут увеличить потенциальную привлекательность каршеринг для пользователей. Создание должной инфраструктуры для поддержки городской мобильности также является приоритетным вопросом, и, следовательно, должно основываться на эмпирических данных, что очередной раз подтверждает необходимость исследования в данном направлении.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. United Nations Framework Convention on Climate Change. Paris Declaration on Electro-Mobility and Climate Change & Call to Action [Электронный ресурс]. – 2015.

2. Migliore M., D’Orso G., Caminiti D. The environmental benefits of carsharing: The case study of Palermo // *Transportation Research Procedia*. – 2020. – Vol. 48. – P. 2127–2139. – DOI: 10.1016/j.trpro.2020.08.271.

3. Shaheen S. A., Schwartz A., Wiprywski K. Policy considerations for carsharing and station cars: Monitoring growth, trends, and overall impacts // *Transportation Research Record*. – 2004. – Т. 1887. – №. 1. – С. 128-136.

4. International Transport Forum. *Road Safety Annual Report 2018*. IRTAD. Paris: OECD Publishing, 2018. 74 p.

5. United Nations. *Sustainable Transport, Sustainable Development: Interagency Report for the Second Global Sustainable Transport Conference*. Beijing, China, 14–16 October 2021. United Nations Department of Economic and Social Affairs, 2021. 92 p.

6. Organisation for Economic Co-operation and Development. *Promoting Clean Urban Public Transportation and Green Investment in Kazakhstan*. OECD Publishing, Paris, 2017. 74 p.

7. Enoch, M.P., & Taylor, J. (2006). A worldwide review of support mechanisms for car clubs. *Transport Policy*, 13(5), 434–443.

8. Buehler R., Dill J. Bikeway networks: a review of effects on cycling // *Transport reviews*. – 2016. – Т. 36. – №. 1. – С. 9-27.

9. Aguilera A., Cacciari J. Living with fewer cars: Review and challenges on household demotorization // *Transport Reviews*. – 2020. – Т. 40. – №. 6. – С. 796-809.

10. Shaheen S. A., Cohen A. P. Carsharing and personal vehicle services: worldwide market developments and emerging trends // *International journal of sustainable transportation*. – 2013. – Т. 7. – №. 1. – С. 5-34.

11. Европейская экономическая комиссия ООН. Проект технического сотрудничества. Укрепление потенциала стран Центральной Азии для разработки политики устойчивой городской мобильности в отношении инициатив по каршерингу и

карпулингу. Женева, 2020, 121 стр.

12. Razmjoo A. et al. Effective policies to overcome barriers in the development of smart cities //Energy Research & Social Science. – 2021. – Т. 79. – С. 102175.

13. McKinsey and Company. (2017). How shared mobility will change the automotive industry.

14. Shaheen S. A., Schwartz A., Wiprywski K. Policy considerations for carsharing and station cars: Monitoring growth, trends, and overall impacts //Transportation Research Record. – 2004. – Т. 1887. – №. 1. – С. 128-136.

15. Shaheen S. A., Cohen A. P. Carsharing and personal vehicle services: worldwide market developments and emerging trends // International journal of sustainable transportation. – 2013. – Т. 7. – №. 1. – С. 5-34.

16. Bondorová B., Archer G. Does sharing cars really reduce car use //Transport & Environment. – 2017. – С. 1-8.

17. Shaheen S. A., Cohen A. P. Carsharing and personal vehicle services: worldwide market developments and emerging trends // International journal of sustainable transportation. – 2013. – Т. 7. – №. 1. – С. 5-34.

18. Nansubuga B., Kowalkowski C. Carsharing: A systematic literature review and research agenda // Journal of Service Management. – 2021. – Т. 32. – №. 6. – С. 55-91.

19. Jorge D., Correia G. Carsharing systems demand estimation and defined operations: a literature review //European Journal of Transport and Infrastructure Research. – 2013. – Т. 13. – №. 3.

20. Laporte G., Meunier F., Wolfler Calvo R. Shared mobility systems //4or. – 2015. – Т. 13. – С. 341-360.

21. Shaheen, S. A. and Cohen, A. P. (2013). Carsharing and personal vehicle services: worldwide market developments and emerging trends. International Journal of Sustainable Transportation, 7:5–34.

22. Francesco Ferrero, Guido Perboli, Mariangela Rosano, Andrea Vesco, Car-sharing services: An annotated review // Sustainable Cities and Society, Volume 37, 2018, Pages 501-518

23. Ter Schure J., Napolitan F., Hutchinson R. Cumulative impacts of carsharing and unbundled parking on vehicle ownership and mode choice //Transportation research record. – 2012. – Т. 2319. – №. 1. – С. 96-104.

24. Hampshire R. C., Gaites C. Peer-to-peer carsharing: Market analysis and potential growth //Transportation research record. – 2011.

– Т. 2217. – №. 1. – С. 119-126.

25. Shaheen S., Cohen A. Innovative Mobility: Carsharing Outlook Carsharing Market Overview, Analysis, And Trends. – 2020.

26. Münzel K. et al. Different business models–different users? Uncovering the motives and characteristics of business-to-consumer and peer-to-peer carsharing adopters in The Netherlands // Transportation Research Part D: Transport and Environment. – 2019. – Т. 73. – С. 276-306.

27. Европейская экономическая комиссия ООН. Будущее мобильности: переход к устойчивым моделям [Электронный ресурс]. – Женева: ЕЭК ООН, 2020. – Режим доступа: <https://unece.org/transport/publications> (дата обращения: 02.07.2025)

28. Ikezoe K., Kiriyama E., Fujimura S. Analysis of car ownership motivation in Tokyo for sustainable mobility service and urban development //Transport Policy. – 2021. – Т. 114. – С. 1-14.

29. Perboli G. et al. Business models and tariff simulation in car-sharing services //Transportation Research Part A: Policy and Practice. – 2018. – Т. 115. – С. 32-48.

30. Curtale, R., Liao, F., Rebalski, J. *Understanding young adults' acceptance of electric carsharing: Evidence from Europe* // Transportation Research Part D: Transport and Environment. – 2022. – Vol. 109. – С. 103353.

31. Turo. *Peer-to-Peer Car Sharing Marketplace* [Электронный ресурс]. – 2024. – Режим доступа: <https://www.turo.com> – (дата обращения: 02.07.2025).

32. Getaround. *Drive with Getaround* [Электронный ресурс]. – 2024. – Режим доступа: <https://www.getaround.com> – (дата обращения: 02.07.2025).

33. Business models and tariff simulation in car-sharing services Francesco Ferrerod , Guido Perbolic,b, Stefano Mussoc , Andrea Vescoa // Car-Sharing Services - Part B Business and Service Models. - 2015.

34. Remane G. et al. A Taxonomy of Carsharing Business Models //ICIS. – 2016. – С. 1-17.

35. Ikezoe K., Kiriyama E., Fujimura S. Analysis of car ownership motivation in Tokyo for sustainable mobility service and urban development //Transport Policy. – 2021. – Т. 114. – С. 1-14.

36. Sy, X., Duan, Y., Cheng, S., Zhang, L. *Determinants of User Intention to Adopt Carsharing Services* // *Journal of Cleaner Production*. – 2022. – Vol. 333. – С. 130203.

37. Tian, Y., Feng, T., Timmermans, H., Yao, T. *Adoption of Car Sharing Services Among Young Adults: An Integrated Model // Travel Behaviour and Society*. – 2021. – Vol. 23. – C. 30–39.

38. Ballús-Armet, I., Shaheen, S. A., Clonts, K., Weinzimmer, D. Peer-to-peer (P2P) carsharing: exploring public perception and market characteristics in the San Francisco Bay Area // *Transportation Research Record: Journal of the Transportation Research Board*. – 2014. – Vol. 2416. – P. 27–36. – DOI: 10.3141/2416-04

39. L. Aversano, M. L. Bernardi, M. Cimitile, P. Ducange, M. Fazzolari and R. Pecori, «An Explainable and Evolving Car Driver Identification System based on Decision Trees,» 2022 IEEE International Conference on Evolving and Adaptive Intelligent Systems (EAIS), 2022, pp. 1-8, doi: 10.1109/EAIS51927.2022.9787517.

40. Mozghan Nasr Azadani, Azzedine Boukerche, DriverRep: Driver identification through driving behavior embeddings, *Journal of Parallel and Distributed Computing*, Volume 162, 2022, Pages 105-117, ISSN 0743-7315, <https://doi.org/10.1016/j.jpdc.2022.01.010>.

41. T. Wakita et al., «Driver identification using driving behavior signals,» *Proceedings. 2005 IEEE Intelligent Transportation Systems*, 2005., 2005, pp. 396-401, doi: 10.1109/ITSC.2005.1520171.

42. M. V. Martínez, J. Echanobe and I. del Campo, «Driver identification and impostor detection based on driving behavior signals,» 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), 2016, pp. 372-378, doi: 10.1109/ITSC.2016.7795582.

43. Ezzini, Saad, Ismail Berrada and Mounir Ghogho. “Who is behind the wheel? Driver identification and fingerprinting.” *Journal of Big Data* 5 (2018): 1-15.

44. Ren, C., An, L., Gu, Z. *et al.* Rebalancing the car-sharing system with reinforcement learning. *World Wide Web* 23, 2491–2511 (2020). <https://doi.org/10.1007/s11280-020-00804-z>

45. L. An, C. Ren, Z. Gu, Y. Wang and Y. Gao, «Rebalancing the Car-Sharing System: A Reinforcement Learning Method,» 2019 IEEE Fourth International Conference on Data Science in Cyberspace (DSC), 2019, pp. 62-69, doi: 10.1109/DSC.2019.00018.

46. Dongbo Liu, Jian Lu, Wanjing Ma, «Real-Time Return Demand Prediction Based on Multisource Data of One-Way Carsharing Systems», *Journal of Advanced Transportation*, vol. 2021, Article ID 6654909, 14 pages, 2021. <https://doi.org/10.1155/2021/6654909>

47. Nihad Brahimi, Huaping Zhang, Lin Dai, Jianzi Zhang, «Modelling on Car-Sharing Serial Prediction Based on Machine Learning and Deep Learning», *Complexity*, vol. 2022, Article ID 8843000, 20 pages, 2022. <https://doi.org/10.1155/2022/8843000>

48. M. Guériau and I. Dusparic, «SAMoD: Shared Autonomous Mobility-on-Demand using Decentralized Reinforcement Learning,» 2018 21st International Conference on Intelligent Transportation Systems (ITSC), 2018, pp. 1558-1563, doi: 10.1109/ITSC.2018.8569608.

49. Peerapon Vateekul, Panyawut Sri-iesaranusorn, Pawit Aiemvaravutigul, Adsadawut Chanakitkarnchok, Kultida Rojviboonchai, «Recurrent Neural-Based Vehicle Demand Forecasting and Relocation Optimization for Car-Sharing System: A Real Use Case in Thailand», *Journal of Advanced Transportation*, vol. 2021, Article ID 8885671, 16 pages, 2021. <https://doi.org/10.1155/2021/8885671>

50. Feifei Zhao, Weiping Wang, Huijun Sun, Hongming Yang. Station-level short-term demand forecast of carsharing system via station-embedding-based hybrid neural network, <https://doi.org/10.1080/21680566.2021.1951885>

51. Bojan Kostic, Mathilde Pryds Loft, Filipe Rodrigues, Stanislav S. Borysov, Deep survival modelling for shared mobility, *Transportation Research Part C: Emerging Technologies*, Volume 128, 2021, 103213, ISSN 0968-090X, <https://doi.org/10.1016/j.trc.2021.103213>

52. C. Xu, K. Zhu, C. Yi and R. Wang, «Data Pricing for Blockchain-based Car Sharing: A Stackelberg Game Approach,» *GLOBECOM 2020 - 2020 IEEE Global Communications Conference*, 2020, pp. 1-5, doi: 10.1109/GLOBECOM42002.2020.9322221

53. Postorino, M.N., Sarnè, G.M.L. (2019). A Neural Network to Identify Driving Habits and Compute Car-Sharing Users' Reputation. In: Esposito, A., Faundez-Zanuy, M., Morabito, F., Pasero, E. (eds) *Quantifying and Processing Biomedical and Behavioral Signals. WIRN 2017 2017. Smart Innovation, Systems and Technologies*, vol 103. Springer, Cham. https://doi.org/10.1007/978-3-319-95095-2_20

54. Meseguer, J.E., Toh, C., Calafate, C.T., Cano, J.C., Manzoni, P.: Drivingstyles: A mobile platform for driving styles and fuel consumption characterization. *arXiv preprint arXiv:1611.09065* (2016)

55. G. Castignani, T. Derrmann, R. Frank and T. Engel, «Driver Behavior Profiling Using Smartphones: A Low-Cost Platform

for Driver Monitoring,» in IEEE Intelligent Transportation Systems Magazine, vol. 7, no. 1, pp. 91-102, Spring 2015, doi: 10.1109/MITS.2014.2328673.

56. A. Diaz Alvarez, F. Serradilla Garcia, J. E. Naranjo, J. J. Anaya and F. Jimenez, «Modeling the Driving Behavior of Electric Vehicles Using Smartphones and Neural Networks,» in IEEE Intelligent Transportation Systems Magazine, vol. 6, no. 3, pp. 44-53, Fall 2014, doi: 10.1109/MITS.2014.2322651.

57. P. Ping, W. Qin, Y. Xu, C. Miyajima and K. Takeda, «Impact of Driver Behavior on Fuel Consumption: Classification, Evaluation and Prediction Using Machine Learning,» in IEEE Access, vol. 7, pp. 78515-78532, 2019, doi: 10.1109/ACCESS.2019.2920489.

58. Umberto Fugiglando, Paolo Santi, Sebastiano Milardo, Kacem Abida, and Carlo Ratti. 2017. Characterizing the «Driver DNA» Through CAN Bus Data Analysis. In Proceedings of the 2nd ACM International Workshop on Smart, Autonomous, and Connected Vehicular Systems and Services (CarSys '17). Association for Computing Machinery, New York, NY, USA, 37–41. <https://doi.org/10.1145/3131944.3133939>

59. Hozhabr Pour, H., Wegmeth, L., Kordes, A., Grzegorzec, M., Wismüller, R. (2020). Feature Extraction and Classification of Sensor Signals in Cars Based on a Modified Codebook Approach. In: Burduk, R., Kurzynski, M., Wozniak, M. (eds) Progress in Computer Recognition Systems. CORES 2019. Advances in Intelligent Systems and Computing, vol 977. Springer, Cham. https://doi.org/10.1007/978-3-030-19738-4_19

60. Emanuele Lattanzi, Valerio Freschi, Machine Learning Techniques to Identify Unsafe Driving Behavior by Means of In-Vehicle Sensor Data, Expert Systems with Applications, Volume 176, 2021, 114818, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2021.114818>.

61. Peppes, Nikolaos, Theodoros Alexakis, Evgenia Adamopoulou, and Konstantinos Demestichas. 2021. «Driving Behaviour Analysis Using Machine and Deep Learning Methods for Continuous Streams of Vehicular Data» *Sensors* 21, no. 14: 4704. <https://doi.org/10.3390/s21144704>

62. Luo, Wei, Yi Wang, Pengpeng Jiao, Zehao Wang, and Pengfei Zhao. 2022. «What Kind of Travellers Are Using Carsharing in Beijing? A Study Based on Selective Ensemble Learning» *Sustainability* 14, no. 1: 540. <https://doi.org/10.3390/su14010540>

63. S. Paul, P. M. Bruntha, A. Raj, S. Saurabh and S. Masih, «Anti-Spoofing Face-Recognition Technique for eKYC Application,» 2021 3rd International Conference on Signal Processing and Communication (ICPSC), 2021, pp. 321-324, doi: 10.1109/ICSPSC51351.2021.9451703.

64. Do, TL., Tran, MK., Nguyen, H.H., Tran, MT. (2021). Potential Threat of Face Swapping to eKYC with Face Registration and Augmented Solution with Deepfake Detection. In: Dang, T.K., Küng, J., Chung, T.M., Takizawa, M. (eds) Future Data and Security Engineering. FDSE 2021. Lecture Notes in Computer Science(), vol 13076. Springer, Cham. https://doi.org/10.1007/978-3-030-91387-8_19

65. Kwak B. I., Woo J., Kim H. K. Know your master: driver profiling-based anti-theft method // *Proceedings of the 14th Annual Conference on Privacy, Security and Trust (PST)*. Auckland, New Zealand, 2016. P. 57–64.

66. Romera E., Bergasa L. M., Arroyo R. Need data for driving behavior analysis? Presenting the public UAH-DriveSet // *Proceedings of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. Rio de Janeiro, Brazil, 2016. P. 387–392. DOI: 10.1109/ITSC.2016.7795609.

67. Schneegass S., Pfleging B., Broy N., Schmidt A., Heinrich F. A data set of real world driving to assess driver workload // *Proceedings of the 5th International Conference on Automotive User Interfaces and Interactive Vehicular Applications (AutomotiveUI '13)*. New York: ACM, 2013. P. 150–157. DOI: 10.1145/2516540.2516561.

68.

69. Venkat, E. (2021). Uber H3 for Data Analysis with Python. Towards Data Science. Available at: <https://towardsdatascience.com/uber-h3-for-data-analysis-with-python-1e54acdcc908>

70. H3. Hexagonal hierarchical geospatial indexing system. Uber Technologies. Available at: <https://h3geo.org>

71. S2 Geometry. Available at: <https://s2geometry.io/>

72. GADM maps and data. GADM. Available at: <https://gadm.org/index.html>

73. Make an impact with your location data. Available at: <https://kepler.gl>

74. Prieto, M., Baltas, G., & Stan, V. (2017). Car sharing adoption intention in urban areas: What are the key sociodemographic drivers? *Transportation Research Part A*, 218-227.

75. New York City Taxi and Limousine Commission. TLC

Trip Record Data : 20092021 [Электронный ресурс]. — Режим доступа: <https://www.nyc.gov/site/tlc/about/tlc-trip-record-data.page>, свободный. — Дата обращения: 04.07.2025.

76. Schaller B. The New Automobility: Lyft, Uber and the Future of American Cities [Электронный ресурс]. — Schaller Consulting, 2018. — URL: <http://www.schallerconsult.com/rideservices/automobility.htm> (дата обращения: 04.07.2025).

77. Uber Technologies Inc. H3: Hexagonal hierarchical geospatial indexing system [Электронный ресурс]. — GitHub. — URL: <https://github.com/uber/h3> (дата обращения: 04.07.2025).

78. Smith J., Zhao L. Static Carsharing Optimization Model for Urban Zones // *Transportation Research Part C*. — 2019. — Vol. 101. — P. 156–170. — DOI: 10.1016/j.trc.2019.02.011.

79. Carsharing: An Industry Overview. — URL: <https://invers.com/en/blog/the-current-state-of-carsharing-an-industry-overview/> (дата обращения: 10.10.2023).

80. Xiao Y., Tian Z., Yu J. A review of object detection based on deep learning // *Multimed Tools Appl.* — 2020. — Т. 79. — С. 23729–23791. — DOI: 10.1007/s11042-020-08976-6.

81. Xiao Y., Tian Z., Yu J. A review of object detection based on deep learning // *Multimed Tools Appl.* — 2020. — Т. 79. — С. 23729–23791. — DOI: 10.1007/s11042-020-08976-6.

82. Ali N. N., Kako N. A., Abdi A. S. Review on Image Segmentation Methods Using Deep Learning // *Proc. 4th Int. Conf. on Advanced Science and Engineering*. — 2022. — С. 7–12. — DOI: 10.1109/ICOASE56293.2022.10075607.

83. Xi W., Chen J., Lin Q., Allebach J. P. High-Accuracy Automatic Person Segmentation with Novel Spatial Saliency Map // *Proc. IEEE Int. Conf. on Image Processing*. — 2019. — С. 1560–1564. — DOI: 10.1109/ICIP.2019.8803063.

84. Strohmayer J., Knapp J., Kampel M. Efficient Models for Real-Time Person Segmentation on Mobile Phones // *Proc. 29th European Signal Processing Conference*. — 2021. — С. 651–655. — DOI: 10.23919/EUSIPCO54536.2021.9616237.

85. Gao F., Li H., Fei J. Segmentation-Based Background-Inference and Small-Person Pose Estimation // *IEEE Signal Processing Letters*. — 2022. — Т. 29. — С. 1584–1588. — DOI: 10.1109/LSP.2022.3186594.

86. Artacho B., Savakis A. UniPose+: A Unified Framework for 2D and 3D Human Pose Estimation in Images and Videos // *IEEE Trans. on Pattern Analysis and Machine Intelligence*. — 2022. — Т. 44.

– № 12. – C. 9641–9653. – DOI: 10.1109/TPAMI.2021.3124736.

87. Noor S. et al. Automatic object tracking and segmentation using unsupervised SiamMask //IEEE Access. – 2021. – T. 9. – C. 106550-106559.

88. Manakitsa N. et al. A review of machine learning and deep learning for object detection, semantic segmentation, and human action recognition in machine and robotic vision //Technologies. – 2024. – T. 12. – №. 2. – C. 15.

89. Terven J., Córdova-Esparza D. M., Romero-González J. A. A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas //Machine Learning and Knowledge Extraction. – 2023. – T. 5. – №. 4. – C. 1680-1716.

90. Wang Z. et al. Towards real-time multi-object tracking // European conference on computer vision. – Cham : Springer International Publishing, 2020. – C. 107-122.

91. Bhola G. et al. Real-time pedestrian tracking based on deep features //2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS). – IEEE, 2020. – C. 1101-1106.

92. Acharya D., Khoshelham K., Winter S. Real-time detection and tracking of pedestrians in CCTV images using a deep convolutional neural network //Proceedings of the 4th Annual Conference of Research@ Locate, Sydney, Australia. – 2017. – C. 3-6.

93. Ye M. et al. Deep learning for person re-identification: A survey and outlook //IEEE transactions on pattern analysis and machine intelligence. – 2021. – T. 44. – №. 6. – C. 2872-2893.

94. Jha M., Tiwari A., Himansh M., Manikandan V. M. Face Recognition: Recent Advancements and Research Challenges // Proc. 2022 13th Int. Conf. on Computing Communication and Networking Technologies. – 2022. – C. 1–6. – DOI: 10.1109/ICCCNT.2022.9851871.

95. Shetty A. B., Rebeiro J. Facial Recognition Using Haar Cascade and LBP Classifiers // Global Transitions Proc. – 2021. – T. 2. – № 2. – C. 330–335.

96. Déniz O., Bueno G., Salido J., De la Torre F. Face Recognition Using Histograms of Oriented Gradients // Pattern Recogn. Lett. – 2011. – T. 32. – № 12. – C. 1598–1603.

97. Ku H., Dong W. Face Recognition Based on MTCNN and Convolutional Neural Network // Front. Signal Process. – 2020. – T. 4. – № 1. – C. 37–42.

98. Kazemi V., Sullivan J. One Millisecond Face Alignment with

an Ensemble of Regression Trees // Proc. IEEE Conf. on Computer Vision and Pattern Recognition. – 2014. – C. 1867–1874. – DOI: 10.1109/CVPR.2014.241.

99. Ahonen T., Hadid A., Pietikainen M. Face Description with Local Binary Patterns: Application to Face Recognition // IEEE Trans. on Pattern Anal. and Mach. Intell. – 2006. – T. 28. – № 12. – C. 2037–2041.

100. Mohanraj V., Vimalkumar M., Mithila M., Vaidehi V. Robust Face Recognition System in Video Using Hybrid Scale Invariant Feature Transform // Procedia Comput. Sci. – 2016. – T. 93. – C. 503–512.

101. Schroff F., Kalenichenko D., Philbin J. FaceNet: A Unified Embedding for Face Recognition and Clustering // Proc. IEEE Conf. on Computer Vision and Pattern Recognition. – 2015. – C. 815–823. – DOI: 10.1109/CVPR.2015.7298682.

102. Koch G., Zemel R., Salakhutdinov R. Siamese Neural Networks for One-Shot Image Recognition // Proc. ICML Deep Learning Workshop. – 2015. – T. 2. – № 1. – C. 1–30.

103. King D. E. Dlib-ML: A Machine Learning Toolkit // J. Mach. Learn. Res. – 2009. – T. 10. – C. 1755–1758.

104. Zhao W., Chellappa R., Phillips P. J., Rosenfeld A. Face Recognition: A Literature Survey // ACM Comput. Surv. – 2003. – T. 35. – № 4. – C. 399–458. – DOI: 10.1145/954339.954342.

105. Buolamwini J., Gebru T. Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification // Proc. Conf. on Fairness, Accountability and Transparency. – 2018. – C. 77–91.

106. Sharif M., Bhagavatula S., Bauer L., Reiter M. K. Accessorize to a Crime: Real and Stealthy Attacks on State-of-the-Art Face Recognition // Proc. 2016 ACM SIGSAC Conf. on Computer and Communications Security. – 2016. – C. 1528–1540.

107. Zhao W., Chellappa R., Phillips P. J., Rosenfeld A. Face Recognition: A Literature Survey // ACM Comput. Surv. – 2003. – T. 35. – № 4. – C. 399–458. – DOI: 10.1145/954339.954342.

108. Fang H., Qian Q. Privacy Preserving Machine Learning with Homomorphic Encryption and Federated Learning // Future Internet. – 2021. – T. 13. – № 4. – C. 94.

109. Deng J., Guo J., Xue N., Zafeiriou S. ArcFace: Additive Angular Margin Loss for Deep Face Recognition // Proc. IEEE/CVF Conf. on Computer Vision and Pattern Recognition. – 2019. – C.

4690–4699.

110. Lanitis A., Taylor C. J., Cootes T. F. Toward Automatic Simulation of Aging Effects on Face Images // *IEEE Trans. on Pattern Anal. and Mach. Intell.* – 2002. – T. 24. – № 4. – C. 442–455.

111. Alotibi M. H., Jarraya S. K., Ali M. S., Moria K. CNN-Based Crowd Counting through IoT // *Procedia Computer Science.* – 2019. – T. 163. – C. 134–144. – DOI: 10.1016/j.procs.2019.12.095.

112. Abu Mangshor N. N., Sabri N., Aminuddin R., et al. Intruder Detection from Video Surveillance Using Deep Learning // *Proc. 2024 IEEE 15th Control and System Graduate Research Colloquium.* – 2024. – C. 87–91. – DOI: 10.1109/ICSGRC62081.2024.10691188.

113. Zhang X., Yi W.-J., Saniie J. Home Surveillance System Using Computer Vision and Convolutional Neural Network // *Proc. 2019 IEEE Int. Conf. on Electro Information Technology.* – 2019. – C. 266–270. – DOI: 10.1109/EIT.2019.8833773.

114. Zhang X., Yi W.-J., Saniie J. Home Surveillance System Using Computer Vision and Convolutional Neural Network // *Proc. 2019 IEEE Int. Conf. on Electro Information Technology.* – 2019. – C. 266–270. – DOI: 10.1109/EIT.2019.8833773.

115. Cleju N., et al. Towards Efficient Urban Mobility: Deployment Strategies for Smart Traffic Management and Crowd Monitoring Systems // *Proc. 2024 Joint European Conf. on Networks and Communications & 6G Summit.* – 2024. – C. 997–1002. – DOI: 10.1109/EuCNC/6GSummit60053.2024.10597063

116. Huang G. B., et al. Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments // *Workshop on Faces in ‘Real-Life’ Images.* – 2008.

117. Cao Q., et al. VGGFace2: A Dataset for Recognising Faces Across Pose and Age // *Proc. 2018 13th IEEE Int. Conf. on Automatic Face & Gesture Recognition.* – 2018. – IEEE.

118. Mumuni A., Mumuni F. Data Augmentation: A Comprehensive Survey of Modern Approaches // *Array.* – 2022. – T. 16. – № 100258. – DOI: 10.1016/j.array.2022.100258.

119. Mikołajczyk-Bareła A., Grochowski M. Data Augmentation for Improving Deep Learning in Image Classification Problem // *Proc. 2018 IEEE Int. PhD Workshop.* – 2018. – C. 117–122. – DOI: 10.1109/IIPHDW.2018.8388338.

ПРИЛОЖЕНИЕ А

Таблица А.1- Риск менеджмент по R2P каршерингу

Риски	Вероятность риска	Последствия риска	Источник риска	Сценарий	Управление риском
1 Кража автомобиля	2 Низкий	3 Экстремально высокий	4 Клиент	5 Человек взял украденное удостоверение личности и водительские права и использовал их в качестве КУС. Как только человек попадает в систему, он / она может легко отсоединить GPS, украсть машину и использовать ее для дальнейших целей (продавать по частям и т. д.).	6 Селфи-матч с КУС. Перед тем, как водить машину, человек должен сделать селфи, и это селфи должно быть совмещено с изображениями КУС. Однако, если у человека есть селфи-фотография, мы должны добавить функцию определения живости, которая будет определять, является ли человек живым человеком или нет (давая определенные действия для выполнения и отслеживая, выполняет ли человек эти действия)
Кража автотранспортных средств	Высокий	Средний	Клиент	Человек взял украденное удостоверение личности и водительские права и использовал их в качестве КУС. Как только человек попадает в систему, он / она может легко украсть детали, а также через удостоверение личности и водительские права после использования автомобиля.	1) Частый осмотр автомобиля (до и после бронирования) 2) Добавьте решение ML, которое может заранее предсказать такие варианты использования 3) селфи-матч с КУС 4) Определение живучести для КУС

Продолжение таблицы В.1- Риск менеджмент по Р2Р каршерингу

1	2	3	4	5	6
Замена автозапчастей автомобиля	Средний	Низкий	Клиент	Человек взял украденное удостоверение личности и водительские права и использовал их в качестве КУС. Как только человек попадает в систему, он / она может легко поменять детали, а также через удостоверение личности и водительские права после использования автомобиля.	1) Частый осмотр автомобиля (до и после бронирования) 2) Добавьте решение ML, которое может заранее предотвратить такие варианты использования 3) селфи-матч с КУС 4) Определение живучести для КУС
Вандализм	Средний	Низкий	Клиент	Человек взял украденное удостоверение личности и водительские права и использовал их в качестве КУС. Как только человек попадает в систему, он / она может легко совершить вандализм с помощью удостоверения личности и водительских прав после использования автомобиля.	1) Сделайте фото авто до и после бронирования (с 8 сторон) 2) Частый осмотр автомобиля (до и после бронирования) 3) Добавьте решение ML, которое может заранее предотвратить такие варианты использования 4) селфи-матч с КУС 4) Определение живучести для КУС

Продолжение таблицы В.1- Риск менеджмент по Р2Р каршерингу

1	2	3	4	5	6
ДТП	Средний	Высокий	Клиент	Любой участник может попасть в аварию, управляя автомобилем.	1) Сделайте фото авто до и после бронирования (с 8 сторон) 2) Частый осмотр автомобиля (до и после бронирования) 3) Добавить решение машинного обучения, которое может заранее предотвратить такие варианты использования (понимание поведения водителя и заблаговременное информирование о плохом поведении водителя). 4) Использование страховки
Мошенничество (использование чужих карт, документов)	Средний	Средний	Клиент	Человек может быть успешно зарегистрирован, однако может использовать украденные карты (например, взятые с черного рынка) и использовать их для управления автомобилем. Это приведет к плохой репутации компании.	1) Добавьте функцию, которая будет определять, используется ли способ оплаты для других клиентов. 2) Проверьте, есть ли у клиента большое количество способов оплаты, которые могут вызвать подозрения. 3) Добавьте модель машинного обучения, которая заранее проинформирует вас, если поведение участника является подозрительным.

Продолжение таблицы В.1- Риск менеджмент по Р2Р каршерингу

1	2	3	4	5	6
Передача управления автомобилем посторонним лицам	Высокий	Низкий	Незарегистрированный клиент	Человек может быть успешно зарегистрирован, однако другие люди (родственники и друзья) могут использовать этот автомобиль от имени зарегистрированного лица. Такая ситуация может привести к различным сценариям, таким как аварии, неправильное поведение при вождении и т. Д.	Использование селфи-совпадений, когда клиент должен сделать селфи, и это селфи должно быть сопоставлено с изображениями КУС. Если лица принадлежат одному человеку, разрешите им водить машину, в противном случае заблокируйте участника.
Агрессивное вождение	Экстремально высокая	Высокий	Клиент	Человек может быть успешно зарегистрирован, однако он может нанести вред автомобилю из-за плохого поведения за рулем. Это приведет к разным повреждениям автомобилей. Лицо может быть успешно зарегистрировано, однако может совершить нарушение во время вождения или парковки. Это приведет к дополнительным штрафам за автомобили и некоторым видам аварий.	Использование модели машинного обучения, которая может информировать о плохом поведении участников. Функции могут быть взяты из GPS, гироскопа и т. Д.
Нарушение правил ПДД	Экстремально высокий	Средний	Клиент	Лицо может быть успешно зарегистрировано, однако может совершить нарушение во время вождения или парковки. Это приведет к дополнительным штрафам за автомобили и некоторым видам аварий.	Проверьте до и после бронирования, не нарушает ли автомобиль какие-либо правила (для этого могут быть привлечены третьи лица). Если да, сообщите об этом покупателю.

Продолжение таблицы В.1- Риск менеджмент по Р2Р каршерингу

1	2	3	4	5	6
Вандализм от 3-х лиц	Средний	Средний	Сторонние люди	Пока машина припаркована на стоянке, третье лицо может повредить машину и совершить с ней различные виды вандализма.	Добавляйте только те автомобили, у которых есть видеорегистратор. Совершая любой вандализм со стороны третьих лиц, мы можем зафиксировать его с помощью видеорегистраторов и решить проблему.
Вождение автомобиля в нетрезвом состоянии или под действием наркотиков	Средний	Высокий	Клиент	Человек может быть успешно подключен к системе, однако, находясь за рулем, водитель может находиться в состоянии алкогольного опьянения или принимать наркотики. Это приведет к широкому спектру случайных случаев.	Перед вождением автомобиля используйте расширенное определение живучести. Люди, находящиеся в состоянии алкогольного опьянения и находящиеся под действием наркотиков, не могут легко выполнить действия, которые потребует система. Следовательно, пьяные клиенты (в том числе потребители наркотиков) не могут водить машину.

Продолжение таблицы В.1- Риск менеджмент по R2R каршерингу

1	2	3	4	5	6
Неправильное поведение со стороны хозяйина	Средний	Низкий	владелец автомобиля	В то время как автомобиль добавляется в систему, может возникнуть ситуация, когда документы на автомобиль неверны, или фотографии автомобиля отличаются от реального автомобиля, или автомобиль может быть украден и т. Д. Это приведет к недовольству клиентов и плохим результатам. репутация компании.	Пока хост добавлен, мы должны дважды проверить и подтвердить, проверен ли хост или нет. Мы также можем добавить «проверенный тег» рядом с хостами, если нет подозрительного поведения / документов.
Поддельные хосты	Низкий	500 000 Низкий	владелец автомобиля	В то время как автомобиль добавляется в систему, может возникнуть ситуация, когда на самом деле автомобиля нет. Это приведет к недовольству клиентов и плохой репутации компании.	Пока хост добавлен, мы должны дважды проверить и подтвердить, проверен ли хост или нет (если машина действительно существует). Мы также можем добавить «проверенный тег» рядом с хостами, если нет подозрительного поведения / документов.

ПРИЛОЖЕНИЕ Б

Бесконтактная система контроля доступа с использованием распознавания лиц в реальном времени

Программа представляет собой бесконтактную систему контроля и управления доступом с использованием технологии распознавания лиц в реальном времени. Она позволяет автоматически идентифицировать пользователя по изображению с видеокамеры, сравнивая его биометрические данные с предварительно зарегистрированной базой.

Система включает в себя следующие модули:

- Модуль видеодетекции, осуществляющий захват и анализ видеопотока с камеры.
- Модуль распознавания лиц, реализованный на основе алгоритмов машинного обучения и нейросетевых эмбеддингов.
- Сервер авторизации, сравнивающий векторные представления лиц с локальной базой пользователей.
- Веб-интерфейс администратора, позволяющий управлять доступом, просматривать логи и редактировать базу лиц.

Программа работает в реальном времени, не требует наличия постоянного подключения к интернету и может быть установлена на устройства с ограниченными вычислительными ресурсами, включая Raspberry Pi. Интерфейс адаптирован для пользователей без специальных технических знаний.

Сфера применения системы охватывает:
- офисные здания, образовательные учреждения, жилые комплексы, склады, лаборатории и другие объекты, где требуется эффективная и безопасная система контроля доступа.

Функциональные возможности программы

Контактная система контроля доступа с распознаванием лиц в реальном времени включает:

- Детектирование лица на видеопотоке с камеры.
- Преобразование лица в эмбеддинги (вектор признаков).
- Сравнение эмбеддингов с базой зарегистрированных пользователей.
- Отображение имени на экране и ведение лога доступа.
- Управление базой пользователей через административную веб-панель.
- Поддержка логирования событий, времени входа и неуспешных попыток доступа.
- Поддержка как онлайн (через API Face++) так и офлайн-режима (локальные модели).

Простота масштабирования и модульная архитектура.

Листинг программы:

```
import face_recognition
import cv2
import os
import numpy as np

KNOWN_FACES_DIR = «known_faces»
TOLERANCE = 0.5
MODEL = «hog» # или «cnn» если есть GPU
FRAME_THICKNESS = 3
FONT_THICKNESS = 2

print(«🔍 Загрузка известных лиц...»)

known_face_encodings = []
known_face_names = []

for name in os.listdir(KNOWN_FACES_DIR):
    person_dir = os.path.join(KNOWN_FACES_DIR, name)

    if not os.path.isdir(person_dir):
        continue

    for filename in os.listdir(person_dir):
        if filename.lower().endswith((«.png», «.jpg», «.jpeg»)):
            image_path = os.path.join(person_dir, filename)
            image = face_recognition.load_image_file(image_path)
            encodings = face_recognition.face_encodings(image)

            if encodings:
                known_face_encodings.append(encodings[0])
                known_face_names.append(name)

print(f«✅ Загружено {len(known_face_encodings)} лиц.»)

# Открываем камеру
video_capture = cv2.VideoCapture(0)

print(«📹 Камера запущена. Нажмите <q> для выхода.»)

while True:
    ret, frame = video_capture.read()
```



```

    if not ret:
        break

    small_frame = cv2.resize(frame, (0, 0), fx=0.25, fy=0.25)
    rgb_small_frame = cv2.cvtColor(small_frame, cv2.
COLOR_BGR2RGB)

    face_locations = face_recognition.face_locations(rgb_small_frame,
model=MODEL)
    face_encodings = face_recognition.face_encodings(rgb_small_frame,
face_locations)

    for face_encoding, face_location in zip(face_encodings, face_locations):
        matches = face_recognition.compare_faces(known_face_encodings,
face_encoding, tolerance=TOLERANCE)
        name = «Неизвестный»

        face_distances = face_recognition.face_distance(known_face_
encodings, face_encoding)
        if len(face_distances) > 0:
            best_match_index = np.argmin(face_distances)
            if matches[best_match_index]:
                name = known_face_names[best_match_index]

    # Рисуем рамку и имя
    top, right, bottom, left = [v * 4 for v in face_location]
    cv2.rectangle(frame, (left, top), (right, bottom), (0, 255, 0),
FRAME_THICKNESS)
    cv2.rectangle(frame, (left, bottom - 35), (right, bottom), (0, 255, 0),
cv2.FILLED)
    cv2.putText(frame, name, (left + 6, bottom - 6), cv2.FONT_
HERSHEY_DUPLEX, 1.0, (255, 255, 255), FONT_THICKNESS)

    cv2.imshow(«Распознавание лиц», frame)

    if cv2.waitKey(1) & 0xFF == ord('q'):
        break

video_capture.release()
cv2.destroyAllWindows()

```

Амиргалиев Бейбут Едилханович

**ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА СОВМЕСТНОГО
ПОЛЬЗОВАНИЯ АВТОМОБИЛЕЙ: БИЗНЕС-
АНАЛИЗ, ПРОЕКТИРОВАНИЕ И ТЕХНОЛОГИИ
ИДЕНТИФИКАЦИИ ПОЛЬЗОВАТЕЛЕЙ**

Монография

*Дизайн обложки: Әбдіжапар Ш.
Компьютерная верстка: Әбдіжапар Ш.*

Подписано в печать 01.07.2025.
Формат 60х84/16.
Объем 8,75 усл. п.л. Тираж 500 экз.

ТОО «Издательство Дарын»
г. Алматы, ул. Жамбыла 114/85,
darynbaspa2022@mail.ru,
+7 747 150 11 77

Отпечатано в типографии ТОО «Дарын баспасы».