

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«РОССИЙСКИЙ ГОСУДАРСТВЕННЫЙ АГРАРНЫЙ УНИВЕРСИТЕТ –
МСХА имени К. А. ТИМИРЯЗЕВА»

На правах рукописи

АБДРАХИМОВ ДАНИИЛ АЛЕКСАНДРОВИЧ

**СИСТЕМА ИДЕНТИФИКАЦИИ
СЕЛЬСКОХОЗЯЙСТВЕННЫХ ЖИВОТНЫХ НА
ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И
ИНФРАКРАСНОЙ СИСТЕМЫ ДЕТЕКЦИИ**

Специальность: 4.3.1

Технологии, машины и оборудование для агропромышленного комплекса

ДИССЕРТАЦИЯ

на соискание учёной степени

кандидата технических наук

Научный руководитель:
кандидат экономических наук,
доцент, доцент кафедры прикладной информатики
Степанцевич Марина Николаевна

Москва — 2025

Оглавление

	Стр.
Введение	5
Глава 1. Состояние вопроса, цель и задачи исследования	13
1.1 Актуальность вопроса	13
1.2 Анализ существующих методов идентификации в АПК	17
1.3 Анализ технологий искусственного интеллекта в задаче детекции	20
1.3.1 Машинное обучение как инструмент визуального распознавания	21
1.3.2 Компьютерное зрение	26
1.4 Анализ технологии инфракрасной идентификации и оценка перспектив использования в АПК	31
1.5 Выводы по главе	35
Глава 2. Теоретические исследования	37
2.1 Обоснование технологической применимости инфракрасной системы идентификации сельскохозяйственных животных	37
2.2 Обоснование технологической применимости искусственного интеллекта	42
2.3 Методология сбора обучающего датасета для обучения моделей искусственного интеллекта	46
2.4 Методология выбора подходящей базовой модели искусственного интеллекта	50
2.5 Методика обучения модели искусственного обучения в задаче детекции свиней	53
2.6 Оценка качества моделей, выбор подходящих метрик качества работы модели в задаче детекции	55
2.7 Методика дистилляции модели. Оценка качества дистиллированной модели. Сравнение с исходной моделью	58
2.8 Исследование разделяющей способности инфракрасной системы идентификации сельскохозяйственных животных	63
2.9 Исследование совместимости результатов модели искусственного интеллекта и инфракрасной системы идентификации сельскохозяйственных животных	66

2.10 Выводы по главе	70
Глава 3. Методика проведения экспериментальных исследований и прототипирования системы идентификации сельскохозяйственных животных . . .	73
3.1 Программа и методика проведения компьютерного моделирование использования системы идентификации сельскохозяйственных животных	73
3.2 Программа и методика проведения лабораторного исследования .	78
3.3 Приборное обеспечение и прототипирование системы идентификации сельскохозяйственных животных	81
3.4 Методика обработки результатов экспериментальных исследований	88
3.5 Программа и методика проведения производственного испытания	90
3.6 Ограничения применимости установки	92
3.7 Выводы по главе	94
Глава 4. Результаты экспериментальных исследований и апробации на производстве	97
4.1 Анализ и результаты компьютерного моделирования	97
4.2 Производственные испытания системы	98
4.3 Оценка устойчивости системы	103
4.4 Выводы по главе	107
Глава 5. Техничко-экономическая оценка применения системы идентификации сельскохозяйственных животных на предприятиях АПК	109
5.1 Оценка готовности системы	109
5.2 Экономическая оценка использования системы идентификации сельскохозяйственных животных в АПК	112
5.3 Выводы по главе	121
Заключение	123
Список сокращений и условных обозначений	126
Список литературы	128

Список рисунков	143
Список таблиц	145
Приложение А. Акты о внедрении результатов диссертационного исследования	146
Приложение Б. Результаты интеллектуальной деятельности . . .	148
Приложение В. Дипломы	151

Введение

Современное животноводство требует внедрения эффективных, автоматизированных и надежных систем идентификации животных, обеспечивающих точный учет и мониторинг поголовья. Традиционные методы, такие как татуировки, бирки и чипирование, обладают рядом недостатков — от низкой надежности и риска потери идентификатора до инвазивности и ограничения объема передаваемой информации. В условиях интенсивного сельского хозяйства эти недостатки снижают оперативность управления и усложняют контроль за состоянием животных. Инфракрасные технологии в сочетании с методами искусственного интеллекта способны не только распознавать животных в режиме реального времени, но и анализировать их физиологическое состояние. Настоящая работа направлена на исследование и разработку интеллектуальной системы идентификации животных, основанной на инфракрасной детекции и алгоритмах машинного обучения. Разработка ориентирована на практическое применение в агропромышленном секторе и призвана повысить эффективность в сфере животноводства. В работе разработана интеллектуальная система идентификации сельскохозяйственных животных, объединяющая преимущества инфракрасной технологии и современных методов искусственного интеллекта для повышения эффективности АПК. Основная идея заключается в использовании ИК-меток, установленных на животных, которые излучают волны в определённом диапазоне, легко фиксируемом недорогими тепловизионными камерами. Такой подход обеспечивает бесконтактную идентификацию, аналогичную RFID-системам, но с меньшими затратами на оборудование и эксплуатацию.

Для обработки видеопотока и выделения животных применялись state-of-the-art архитектуры компьютерного зрения, в частности модели семейства YOLO (You Only Look Once), способные в реальном времени определять местоположение животного в кадре. Обучение нейросетей проводилось на специально собранном датасете. Далее идентификация осуществлялась на основе анализа уникальных тепловых паттернов ИК-меток. Таким образом, была создана система, которая сочетает в себе автоматизированную высокоточную детекцию, низкие эксплуатационные издержки и простоту интеграции в существующую инфраструктуру сельскохозяйственных предприятий, предлагая

сбалансированное решение между дорогими интеллектуальными системами и устаревшими ручными методами.

Степень разработанности. Большой вклад в исследование процессов автоматизации процессов сельскохозяйственного производства внесли следующие ученые: О.Н. Дидманидзе, В.В. Кирсанов, С.Н. Девянин, Н.Н. Пуляев, А.А. Манохина, О.А. Леонов, А.С. Дорохов, О.А. Иващук, Н.В. Алдошин и другие. В их работах рассмотрены ключевые подходы автоматизации ведения сельского хозяйства.

Актуальность темы. Актуальность работы обусловлена необходимостью модернизации процессов идентификации сельскохозяйственных животных в условиях стремительного развития цифровых технологий и автоматизации в агропромышленном комплексе. Традиционные методы не обеспечивают достаточной точности и оперативности при масштабном мониторинге поголовья, особенно на крупных фермах. В этом контексте инфракрасные технологии в сочетании с алгоритмами искусственного интеллекта открывают новые возможности для бесконтактной, высокоточной и автоматизированной идентификации животных. Такая интеграция позволяет не только повысить точность учета и мониторинга, но и сократить стресс у животных, минимизировать человеческий фактор и повысить производственную эффективность. Разработка и внедрение интеллектуальных систем идентификации становятся важным шагом к цифровизации аграрного сектора и повышению его технологического уровня.

Целью данной работы является создание интеллектуальной системы идентификации сельскохозяйственных животных на основе методов искусственного интеллекта и инфракрасной детекции для повышения эффективности животноводческой отрасли.

Для достижения поставленной цели были решены следующие **задачи**:

1. Проанализировать современные подходы к идентификации сельскохозяйственных животных, выявив их преимущества и ограничения с точки зрения точности, удобства использования и экономической эффективности.
2. Исследовать потенциал применения инфракрасных технологий для бесконтактной идентификации животных, рассматривая физические параметры теплового излучения, особенности диапазонов ИК-спектра и возможные варианты конструкции ИК-меток.

3. Разработать подход к формированию обучающего датасета на основе тепловых изображений животных с необходимой разметкой, обеспечивающей возможность эффективного обучения моделей компьютерного зрения.
4. Изучить и обосновать выбор нейросетевых архитектур таких, как YOLO, EfficientDet и др., наилучшим образом подходящих для решения задач детекции и идентификации животных по инфракрасным изображениям.
5. Провести обучение и тестирование выбранной модели, оценив её точность, производительность и устойчивость к внешним воздействиям (освещение, загрязненность).
6. Создать экспериментальный прототип системы, включающей в себя инфракрасную камеру, модуль обработки и хранения данных, а также программное обеспечение на основе обученной нейросети.
7. Выполнить лабораторные и производственные испытания прототипа, проанализировать его функциональность, надёжность и точность работы.
8. Провести технико-экономическую оценку внедрения разработанной системы, включая расчёт затрат на оборудование, эксплуатационные расходы и эффективность от повышения качества мониторинга.

Внедрение интеллектуальной системы позволит значительно повысить эффективность управления поголовьем, улучшить процессы учета и мониторинга, а также оптимизировать логистические и производственные цепочки в животноводческой индустрии. Таким образом, интеграция искусственного интеллекта и инфракрасной детекции открывает новые возможности для повышения продуктивности и устойчивого развития сельского хозяйства. В рамках реализации данной разработки ставилась задача объединить преимущества инфракрасных меток — как недорогих и неинвазивных идентификаторов — с возможностями современных алгоритмов компьютерного зрения и машинного обучения, способных обрабатывать тепловые изображения в реальном времени. Разработанная система распознает конкретное животное по излучающей метке, определяет его местоположение и сопоставляет с базой данных. При этом особое внимание уделялось сохранению технологической и экономической доступности решения, что предполагает использование бюджетного аппаратного обеспечения и алгоритмически оптимизированных моделей на базе нейросетей. В основе целе-

полагания данного исследования лежит создание практикоориентированной и масштабируемой системы, способной работать в условиях интенсивного животноводства, обеспечивая точную идентификацию без необходимости физического контакта с животными.

Предмет и объект исследования. Объектом исследования является процесс автоматизированной идентификации и мониторинга поголовья сельскохозяйственных животных. Предмет исследования — методика и программно-аппаратная реализация интеллектуальной системы идентификации, основанной на анализе инфракрасных изображений с применением алгоритмов машинного обучения.

Научная новизна. Разработана оригинальная автоматизированная система идентификации сельскохозяйственных животных на основе технологий инфракрасной детекции и алгоритмов искусственного интеллекта.

Теоретическая и практическая значимость

1. Система применима для идентификации и отслеживания состояния большинства сельскохозяйственных животных.
2. Разработанные алгоритмы и программное обеспечение способствуют повышению эффективности мониторинга сельскохозяйственных животных.
3. Модульная архитектура разработанной системы позволяет легко встраивать ее в информационную систему большинства сельскохозяйственных предприятий без необходимости радикального переоснащения или изменения технологических процессов.
4. Система позволяет отслеживать уникальные идентификаторы и ключевые характеристики отдельных особей, что подтверждается комплексной оценкой работоспособности системы в ООО «Башкирская мясная компания» и ООО «Агромилк» (приложение А) с учетом факторов, влияющих на тепловую сигнатуру животных (температура окружающей среды, активность, шерстный покров).

Методология и методы исследования. В настоящей работе использовались:

1. Методы искусственного интеллекта и машинного обучения — применялись для разработки и обучения нейросетевых моделей (в частности, YOLO) с целью автоматической детекции и идентификации животных по инфракрасным изображениям.

2. Методы компьютерного зрения — использовались для обработки видеопотока и выделения объектов (животных) на фоне, а также для сопоставления визуальных и тепловых признаков с индивидуальными идентификаторами.
3. Методы тепловизионного анализа — применялись для изучения характеристик инфракрасного излучения животных и оптимального размещения ИК-меток, обеспечивающих устойчивую идентификацию.
4. Методы цифровой обработки изображений — использовались для предобработки данных (нормализация, увеличение контрастности, фильтрация «шумов»), а также для выделения ключевых признаков на инфракрасных изображениях.
5. Методы прототипирования аппаратно-программных систем — использовались при сборке и отладке системы, включающей тепловизионную камеру, вычислительный модуль и программное обеспечение.
6. Методы экспериментальных исследований — применялись при лабораторных и производственных испытаниях системы с целью верификации точности, надежности и устойчивости работы в условиях животноводческого предприятия.
7. Методы сравнительного анализа — использовались для сопоставления предложенной системы с традиционными методами идентификации (бирки, RFID, чипирование) по ключевым критериям: точность, стоимость, удобство, масштабируемость.

Основные положения, выносимые на защиту:

1. Разработанная интеллектуальная система идентификации сельскохозяйственных животных, основанная на интеграции инфракрасной детекции и алгоритмов искусственного интеллекта, обеспечивающая бесконтактную, точную и автоматизированную идентификацию.
2. Методика формирования обучающего датасета тепловых изображений животных с разметкой инфракрасных меток, пригодная для обучения нейросетевых моделей детекции и распознавания в инфракрасном диапазоне.
3. Результаты оценки технико-экономической эффективности применения системы идентификации сельскохозяйственных животных с помощью искусственного интеллекта и инфракрасной системы детекции.

Достоверность полученных результатов обеспечивается использованием адекватных подходов к решению поставленных задач. Полученные результаты соответствуют данным наблюдений, а также согласуются с результатами, которые получены другими авторами с применением альтернативных методов детекции.

Апробация работы. Основные результаты работы докладывались на следующих конференциях и научных форумах: Всероссийская научно-практическая конференция, посвященная 80-летию высшего землеустроительного образования в Пермском крае, Международная научно-практическая конференция в Твери «Развитие научно-инновационного потенциала аграрного производства: проблемы, тенденции, пути решения», Международная научно-практическая конференция «Цифровые компетенции – сельскому хозяйству», г. Москва. Система апробирована в ООО «Башкирская мясная компания», ООО «Агромилк» (приложение А), получена положительная обратная связь о работе системы от представителей агробизнеса.

Результаты работы представлены международному сообществу на конференции BRICS Industrial Innovation Contest 2024 в Китае и отмечены как выдающийся проект в области автоматизации животноводства. Система была продуктивизирована и представлена на конкурсе «Студенческий стартап 2023» и признана победителем по направлению цифровые технологии (приложение В).

Личный вклад. Автор лично проводил анализ литературных и натуральных данных, активно участвовал в постановке цели и задач исследования, строил модели, разрабатывал систему, обрабатывал и анализировал результаты, формулировал выводы. Представленные автором теоретические аспекты и модели оригинальны. Автор активно участвовал в подготовке публикаций, а также докладов на научных конференциях.

Публикации. Основные результаты по теме диссертации изложены в 5 печатных изданиях, 2 из которых изданы в журналах, рекомендованных ВАК Минобрнауки РФ, 3 — в тезисах докладов. Зарегистрированы 3 программы для ЭВМ.

Объем и структура работы. Диссертация состоит из введения, 5 глав, заключения. Полный объем диссертации составляет 152 страницы, включая 32 рисунка и 12 таблиц. Список литературы содержит 113 наименований. Структура диссертации имеет следующий вид:

- Глава 1 В первой главе обосновывается актуальность разработки современных систем идентификации животных в условиях цифровизации сельского хозяйства. Традиционные методы маркировки (ушные бирки, татуировки, чипирование), несмотря на широкое распространение, обладают существенными недостатками, включая низкую надежность, необходимость физического контакта и стрессовое воздействие на животных.

Перспективной альтернативой выступает технология инфракрасной идентификации, интегрированная с компьютерным зрением и алгоритмами машинного обучения. Данный подход обеспечивает бесконтактный мониторинг с точностью до 98%, автоматизированный учет поголовья и раннее выявление заболеваний. Ключевыми преимуществами системы являются снижение эксплуатационных затрат, минимизация человеческого фактора и соответствие современным стандартам гуманного животноводства.

Развитие технологии требует совершенствования алгоритмов обработки тепловых изображений с учетом изменяющихся условий среды. Внедрение таких решений создает основу для полностью автоматизированных систем управления фермерскими хозяйствами, что способствует повышению продуктивности и продовольственной безопасности. Переход на современные методы идентификации обусловлен не только технико-экономической эффективностью, но и необходимостью соответствия вызовам цифровой трансформации АПК.

- Глава 2 Во второй главе содержится теоретическое исследование, которое обосновывает возможность применения изложенного подхода [2]. Также подробно освещается обоснование технологической применимости искусственного интеллекта, разрабатывается система метрик контроля и валидации полученных от моделей результатов, описывается процесс дистилляции, а также проводится комплексное сравнение качества модели до и после дистилляции.
- Глава 3 Глава посвящена методике проведения экспериментальных исследований и прототипирования системы. Подробно описываются пограничные условия, выбираются условия для компьютерного моделирования и проверки работоспособности системы, описывается методика проведения эксперимента, а также многочисленные тесты, покрываю-

щие все необходимые части представленной гетерогенной архитектуры. Разрабатывается методика оценки результатов экспериментов. Формулируются основные условия применимости метода и установки. Основные итоги были опубликованы в [1].

- Глава 4 Глава содержит результаты экспериментальных исследований и апробации на производстве. Освещены основные плюсы и минусы системы, выявленные в ходе внедрения системы на производстве [2].
- Глава 5 Глава посвящена технико-экономической оценке использования новой системы идентификации. Рассматриваются основные факторы влияющие на экономическую эффективность предложенного подхода, оценивается готовность системы идентификации, рассчитываются основные показатели эффективности применения системы.

Глава 1. Состояние вопроса, цель и задачи исследования

1.1 Актуальность вопроса

Современное сельское хозяйство стремительно развивается [3; 97], внедряя передовые технологии [21; 36] для повышения эффективности и продуктивности животноводства. Одним из ключевых направлений являются автоматизация и цифровизация процессов идентификации сельскохозяйственных животных [5], который играет важную роль в управлении сельскохозяйственными предприятиями [64; 77], обеспечении здоровья поголовья и контроле за производственными показателями. [4; 48] В условиях современного животноводства эффективная идентификация животных [28; 83; 84; 104] является важнейшей составляющей системы управления сельскохозяйственным предприятием [66; 79], поскольку от этого зависит не только точность учета, но и оперативность принятия управленческих решений, а также качество мониторинга здоровья и продуктивности особей. Традиционные методы, такие как ушные бирки, татуировки и чипирование, применяются уже на протяжении десятилетий и получили широкое распространение благодаря своей относительной простоте и доступности. Однако при детальном анализе их эксплуатационных характеристик становится очевидным, что данные подходы сопряжены с рядом существенных недостатков. Так, ушные бирки, являясь внешними идентификаторами, подвержены механическим повреждениям и могут быть легко утрачены или повреждены в процессе жизнедеятельности животного, что приводит к потере идентификационных данных и требует дополнительных усилий для их восстановления. Аналогичные проблемы наблюдаются и при использовании татуировок, которые, несмотря на свою долговечность, наносятся с определенной степенью инвазивности, вызывая стресс [82] и дискомфорт у животных, а также могут быть стерты или затерты с течением времени под воздействием физиологических процессов. Технология чипирования, которая предполагает введение под кожу небольшого электронного устройства, позволяет добиться высокой степени надежности идентификации, однако данная процедура требует обязательного физического контакта с животным и применения специализированного оборудования для считывания данных, что не всегда может быть

реализовано в условиях интенсивного животноводства и большого поголовья. В свете указанных ограничений все более перспективной становится технология инфракрасной идентификации, которая представляет собой инновационное решение для бесконтактного и высокоточного определения животных. Принцип работы данной технологии основан на регистрации длин волн в инфракрасном диапазоне, совместно с технологией компьютерного зрения. Нейронные сети с высокой разрешающей способностью могут определять уникальный идентификатор особи, объединяя ее с методами детекции животных в видео потоке [43], таким образом получая координаты животного и ее уникальный идентификатор, анализируя видеопоток [27]. При этом применение инфракрасных методов позволяет автоматизировать процесс мониторинга, поскольку современные системы оснащаются алгоритмами обработки изображений и машинного обучения, способными анализировать тепловые данные в реальном времени и сопоставлять их с базой уникальных идентификаторов. Научные исследования, проводимые в данной области, демонстрируют, что интеграция инфракрасной технологии в систему идентификации позволяет не только повысить точность регистрации, но и существенно оптимизировать процесс управления предприятием [24]. Благодаря возможности дистанционного сканирования, сельскохозяйственные предприятия получают возможность проводить регулярный и оперативный контроль состояния животных, что способствует более раннему выявлению заболеваний и нарушений в физиологическом состоянии особей. Преимущество данного подхода заключается в том, что он минимизирует влияние внешних факторов, таких как механические повреждения и человеческий фактор, что характерно для традиционных методов идентификации. Более того, бесконтактный характер технологии способствует созданию условий для более комфортного и гуманного обращения с животными, что соответствует современным требованиям, стандартам животноводства и повышению качества продукции. Развитие инфракрасной идентификации также требует совершенствования программного обеспечения для анализа тепловых изображений, что представляет собой интеграцию передовых технологий искусственного интеллекта и алгоритмов глубокого обучения. Эти программные решения способны не только распознавать индивидуальные идентификаторы особей, но и адаптироваться к изменениям внешних условий, таким как колебания температуры окружающей среды или особенности шерстного покрова различных пород. Данная технологическая интеграция открывает перспективы

для создания полностью автоматизированных систем контроля и мониторинга, что в свою очередь способствует повышению эффективности функционирования сельскохозяйственных предприятий, снижению операционных затрат и повышению уровня продовольственной безопасности [42; 109]. Таким образом, традиционные методы идентификации, несмотря на их историческую значимость и широкое применение, сталкиваются с рядом серьезных технологических и практических ограничений [99], что обуславливает необходимость перехода к более современным и надежным решениям. Инфракрасная идентификация, обладая рядом преимуществ, таких как бесконтактность, высокая точность и возможность автоматизации, представляет собой перспективное направление в развитии технологий мониторинга и управления животными. Внедрение данной технологии не только решает проблемы, связанные с утратой идентификационных элементов и сложностями их применения, но и способствует созданию более безопасной, эффективной и гуманной системы ведения животноводства, что является важным аспектом в контексте современных аграрных инноваций [104; 110].

В современном сельском хозяйстве внедрение технологий инфракрасной идентификации может стать ключевым элементом для повышения эффективности мониторинга состояния животных и оптимизации управления предприятием [33; 57; 61]. Применение данной технологии обусловлено способностью инфракрасных датчиков регистрировать тепловое излучение, исходящее от инфракрасных меток, что позволяет не только определить их местоположение и идентичность, но и получить информацию о физиологических изменениях в организме. Такая возможность анализа тепловых характеристик дает ученым и специалистам в области животноводства инструмент для раннего обнаружения патологических процессов, позволяя своевременно реагировать на появление признаков заболеваний и снижать связанные с ними экономические потери. Технология инфракрасной идентификации опирается на высокоточные датчики, способные фиксировать мельчайшие изменения температуры, что является отражением специфических физиологических процессов, происходящих в организме животного. Регистрация инфракрасного сигнала не требует физического контакта, что является значительным преимуществом по сравнению с традиционными методами идентификации, такими как использование ушных бирок, татуировок или чипирования. Бесконтактный характер метода способствует снижению стресса у животных и минимизирует риск возникнове-

ния травм как у самих животных, так и у обслуживающего персонала, что в свою очередь положительно сказывается на общем уровне продуктивности и благополучия животных в условиях интенсивного животноводства. [16; 19] Интеграция инфракрасных систем идентификации с современными алгоритмами обработки данных и технологиями искусственного интеллекта открывает новые возможности для автоматизации процессов мониторинга. Системы, оборудованные специализированным программным обеспечением, способны анализировать динамику тепловых профилей животных в режиме реального времени, что позволяет не только проводить идентификацию, но и осуществлять диагностику физиологического состояния на ранних стадиях развития патологий. Такой подход значительно повышает точность и оперативность принятия управленческих решений в аграрном секторе, позволяя своевременно корректировать методы ухода и профилактики заболеваний [107].

Развитие инфракрасных методов идентификации тесно связано с глобальными тенденциями по внедрению цифровых технологий и автоматизированных систем в сельскохозяйственное производство [6; 68]. В условиях, когда объемы данных, получаемых от сельскохозяйственных объектов, постоянно возрастают, актуальность разработки инновационных методов учета и мониторинга поголовья становится особенно высокой. Исследования в данной области направлены на улучшение характеристик инфракрасных датчиков, повышение их чувствительности и точности, а также на разработку интегрированных систем, способных объединить данные, полученные из различных источников, и предоставить комплексное представление о состоянии животных. Такой междисциплинарный подход способствует формированию новых стандартов в области мониторинга, где биометрические данные и алгоритмы машинного обучения играют ключевую роль. Кроме того, использование инфракрасной идентификации в сельском хозяйстве способствует переходу к более устойчивым и экономически эффективным методам управления поголовьем. Технология позволяет оптимизировать процесс распределения ресурсов, снизить затраты на ручной контроль и обеспечить непрерывное наблюдение за здоровьем животных. Это, в свою очередь, создает условия для повышения качества конечной продукции, улучшения санитарно-гигиенических показателей и формирования благоприятной экосистемы сельскохозяйственных предприятий. Таким образом, развитие и внедрение инфракрасных систем идентификации представляет собой значительный шаг вперед в решении задач

современного животноводства [26]. Объединение точного мониторинга местоположения, идентификации и анализа физиологического состояния животного с высокими возможностями обработки данных позволяет создать комплексные системы контроля, способные удовлетворить потребности крупных аграрных предприятий. В условиях динамичного развития технологий и растущей потребности в автоматизации сельскохозяйственных процессов, исследования в области инфракрасной идентификации животных приобретают особую актуальность, открывая перспективы для дальнейшего совершенствования методов учета, диагностики и управления стадом.

1.2 Анализ существующих методов идентификации в АПК

Современное производство использует широкий набор методов идентификации животных — от традиционных, проверенных временем решений, таких как татуировки и ушные выщипы, до высокотехнологичных систем на основе радиочастотной идентификации и микрочипов [104]. Выбор конкретного метода определяется задачами производства и его экономической целесообразностью [101]. Сравнительная характеристика всех методов представлена в таблице 1.1.

Метод татуировки заключается в нанесении уникальной метки на кожу животного при помощи специальных инструментов. Он отличается простотой, низкой стоимостью, долговечностью и устойчивостью к внешним воздействиям. Татуировка обеспечивает долгосрочную идентификацию и легко читается визуально, не требуя специального оборудования. Однако процедура болезненна, связана с риском заражения и требует соблюдения санитарных норм. Татуировки могут быть трудночитаемыми у животных с тёмной кожей и не всегда удобны для считывания на расстоянии. Кроме того, они ограничены по объёму передаваемой информации и могут вызывать этические споры.

Метод выщипов на ушах основан на вырезании фрагментов кожи определённой формы. Такие метки долговечны, устойчивы к внешним воздействиям и позволяют создавать уникальные идентификаторы. Они легко читаются визуально и экономичны, не вызывая дискомфорта после нанесения. К недостаткам относятся болезненность процедуры, риск инфицирования и трудности визу-

Таблица 1.1 — Сравнительная характеристика методов идентификации животных

Метод	Преимущества	Недостатки	Техническо - экономическая характеристика
Татуировка	Простота, низкая стоимость, долговечность	Болезненность, риск заражения, малая информативность	Низкая стоимость, низкая автоматизация, низкий объём информации
Ушные выщипы	Долговечность, уникальность, простота	Болезненность, риск инфекции, малая информативность	Низкая стоимость, низкая автоматизация, низкий объём информации
Холодное таврение	Долговечность, хорошая видимость, минимальный дискомфорт	Требует оборудования, малая информативность	Средняя стоимость, низкая автоматизация, низкий объём информации
Биркование	Простота, дешевизна, долговечность	Риск потери, необходимость замены	Низкая стоимость, низкая автоматизация, низкий объём информации
Ошейники и браслеты	Высокая точность, автоматизация, сбор данных	Высокая стоимость, риск потери	Высокая стоимость, высокая автоматизация, средний объём информации
Чипирование	Долговечность, точность, безопасность	Высокая стоимость, ограниченная дальность	Высокая стоимость, средняя автоматизация, высокий объём информации
RFID-метки	Точность, дистанционное считывание, автоматизация	Высокая стоимость, ограниченная дальность	Высокая стоимость, высокая автоматизация, средний объём информации
ИК-метки	Низкая стоимость, безопасность, высокая разрешающая способность	Необходимость оборудования, разработка ПО	Средняя стоимость, средняя автоматизация, средний объём информации

ального считывания с расстояния. Повреждения или заболевания уха могут ухудшить читаемость метки, а объём кодируемой информации остаётся ограниченным.

Холодное таврение основано на использовании жидкого азота, который изменяет пигментацию шерсти или разрушает волосяные фолликулы, образуя видимое тавро. Преимуществами метода являются долговечность, хорошая видимость метки и минимальный дискомфорт для животного. Кожа при этом не повреждается, а сама метка устойчива к подделкам. Основные недостатки — необходимость специального оборудования и соблюдения мер безопасности при работе с жидким азотом, ограниченность информации, которую можно зафиксировать, и зависимость качества результата от опыта оператора.

Биркование заключается в прикреплении бирки к уху животного. Метод прост в реализации, недорог, долговечен и универсален. Бирки легко читаются и вызывают минимальный дискомфорт. Основные проблемы связаны с риском потери бирки, повреждением уха при неправильном нанесении, необходимостью замены изношенных бирок и ограниченным объёмом информации.

Ошейники и браслеты представляют собой устройства с сенсорами, которые помимо идентификации позволяют собирать данные о передвижении, поведении и состоянии животных. Они обеспечивают высокую точность и автоматизацию процессов, просты в использовании и не мешают животным. Недостатками являются высокая стоимость оборудования и обслуживания, зависимость от качества устройств, риск их потери или повреждения, необходимость технической инфраструктуры и регулярной подзарядки.

Чипирование подразумевает имплантацию микрочипа под кожу животного. Этот метод отличается долговечностью, высокой точностью, безопасностью и невозможностью подделки. Он позволяет хранить дополнительную информацию в базах данных. Недостатки включают высокую стоимость микрочипов и оборудования, ограниченную дальность считывания, риск миграции микрочипа и зависимость от качества оборудования.

RFID-метки используют радиочастотную идентификацию и обеспечивают точное, быстрое и дистанционное считывание данных. Они долговечны, автоматизируют производственные процессы и интегрируются с цифровыми системами управления. Основные ограничения связаны с высокой стоимостью оборудования, необходимостью технической инфраструктуры, ограниченной дальностью считывания и риском потери меток.

Инфракрасный метод идентификации основан на использовании ИК-излучения определённой частоты [45]. Он отличается компактностью, экономичностью, безопасностью и высокой разрешающей способностью, не вызывая дискомфорта у животных. К его недостаткам относятся необходимость специального оборудования, разработка программного обеспечения и риск потери или повреждения меток.

Таким образом, различные методы идентификации животных обладают своими преимуществами и недостатками, которые необходимо учитывать при выборе технологии для конкретного сельскохозяйственного предприятия. Традиционные методы остаются востребованными за счёт простоты и низкой стоимости, тогда как современные цифровые решения обеспечивают более высокий уровень автоматизации и контроля.

1.3 Анализ технологий искусственного интеллекта в задаче детекции

Современные исследования в области применения искусственного интеллекта демонстрируют его решающее значение для разработки автоматизированных систем, предназначенных для детекции и идентификации сельскохозяйственных животных. В настоящее время алгоритмы машинного обучения, интегрированные с методами компьютерного зрения, обеспечивают возможность систематической обработки больших массивов данных, что позволяет не только извлекать из них ключевую информацию, но и анализировать тонкие различия в морфологических и поведенческих характеристиках животных. Такой подход способствует повышению точности идентификации посредством детального выделения уникальных признаков каждой особи, что особенно важно в условиях интенсивного животноводства. Интеграция цифровых технологий в существующие системы наблюдения за животными открывает возможности для более точного и рационального управления ресурсами хозяйства. Такой подход позволяет сократить влияние субъективных факторов, связанных с человеческим участием, и способствует повышению качества контроля за состоянием животных. В последние годы особое внимание уделяется разработке и внедрению интеллектуальных алгоритмов, адаптированных под

конкретные задачи аграрного сектора. Это даёт возможность формировать универсальные платформы, способные эффективно анализировать быстро меняющиеся условия содержания животных. Применение комплексных интеллектуальных решений на базе современных ИИ-технологий позволяет достичь значительного прогресса в области диагностики, прогнозирования и выработки решений, направленных на устойчивое развитие сельскохозяйственного производства.

1.3.1 Машинное обучение как инструмент визуального распознавания

В контексте современных исследований, связанных с визуальной идентификацией сельскохозяйственных животных, алгоритмы машинного обучения играют ключевую роль, обеспечивая автоматизированную обработку изображений и повышение точности классификации объектов. Анализ публикаций в данной области показывает наличие двух основных направлений развития: традиционные (классические) методы и технологии глубокого обучения. К первому направлению относят такие алгоритмы, как метод опорных векторов (SVM), деревья решений, случайные леса и алгоритмы ближайших соседей. Эти подходы применяются при анализе конкретных морфологических характеристик животных, позволяя выделять ключевые признаки на основе заранее подготовленных данных. Несмотря на свою эффективность в ряде задач, такие методы ограничены в обработке высокоразмерных и вариативных визуальных данных, особенно в условиях изменчивого освещения, фона или положения объекта.

Современные подходы, основанные на глубоком обучении, включая сверточные и рекуррентные нейронные сети, демонстрируют значительно более высокую точность и гибкость. Их преимущество заключается в способности автоматически извлекать значимые признаки из изображений без необходимости ручной разметки признаков. Это позволяет эффективно распознавать животных даже в нестандартных условиях съёмки, что особенно актуально при работе с видеопотоком, полученном на животноводческих комплексах. Такие методы не только улучшают идентификацию, но и способствуют созданию интеллектуальных систем, способных адаптироваться к различным сценариям работы.

Комбинация классических и глубоких методов машинного обучения представляет собой перспективное направление развития, обеспечивающее баланс между интерпретируемостью и высокой производительностью. Это объединение усилий разных подходов создаёт потенциал для разработки устойчивых, масштабируемых и точных систем анализа визуальной информации, востребованных в цифровом сельском хозяйстве. Методы классического машинного обучения лежат в основе большинства прикладных решений, когда речь идёт о задачах классификации, регрессии и кластерного анализа. Отличительной особенностью этих алгоритмов является требование к предварительной обработке и векторному представлению входных данных. При наличии качественно размеченного набора признаков они позволяют достаточно эффективно решать широкий спектр задач, особенно в условиях ограниченного объёма обучающих данных и при необходимости интерпретации результатов. Эти методы зародились на стыке статистики и вычислительной математики, что позволило создать модели, способные описывать взаимосвязи между входными данными и целевыми переменными посредством оптимизации функционалов ошибки. В основе классических методов лежит предположение о наличии явной структуры в данных, что позволяет применять строгие математические модели для её описания.

Одним из ключевых аспектов классических алгоритмов является процесс выделения признаков, представляющих собой предварительную обработку и преобразование исходных данных в форму, пригодную для дальнейшего анализа. В отличие от методов глубокого обучения, где признаки извлекаются автоматически, классические подходы требуют тщательной ручной предварительной обработки признаков, что обусловлено необходимостью выявления релевантных характеристик, способных адекватно отразить сущность изучаемых объектов. Такой подход имеет важное значение, поскольку качество конечного результата напрямую зависит от степени информативности выбранных признаков и от способности алгоритма эффективно использовать данную информацию.

Алгоритмы, основанные на методе опорных векторов, демонстрируют высокую эффективность в задачах бинарной и многоклассовой классификации, используя концепцию гиперплоскостей, разделяющих данные с максимальным зазором. Подобный принцип позволяет минимизировать риск переобучения и обеспечить устойчивость модели к выбросам, что особенно важно при работе с ограниченными объемами данных. Методы, основанные на построении ре-

шающих деревьев, применяют итеративный процесс разбиения пространства признаков, что способствует построению интерпретируемых моделей, позволяющих исследователю понять влияние каждого параметра на итоговый результат. Данный подход обладает высокой наглядностью, что делает его привлекательным для использования в прикладных исследованиях, где интерпретируемость результатов имеет первостепенное значение.

Еще одной важной категорией классических методов являются ансамблевые алгоритмы, такие как случайные леса, которые объединяют результаты множества отдельных моделей для получения более устойчивого и точного прогноза. Такой подход позволяет компенсировать недостатки отдельных алгоритмов, повышая общую надежность системы за счет использования коллективного мнения. Кроме того, методы, основанные на анализе ближайших соседей, используют концепцию локальной близости объектов в пространстве признаков, что делает их эффективными при наличии ярко выраженной кластеризации данных, однако при этом они требуют корректной настройки гиперпараметров для избежания проблем, связанных с высокой размерностью пространства.

Практическая применимость классических методов машинного обучения обуславливается их относительно низкими вычислительными затратами по сравнению с современными методами глубокого обучения, что позволяет использовать данные алгоритмы в условиях ограниченных вычислительных ресурсов. При этом модели, полученные с использованием данных методов, обладают высокой степенью интерпретируемости, что является существенным преимуществом в ситуациях, требующих объяснимости результатов анализа. В задачах анализа визуальных данных и физических характеристик сельскохозяйственных животных классические алгоритмы машинного обучения по-прежнему демонстрируют приемлемый уровень точности, особенно при условии тщательной подготовки входных данных. Этап предварительной обработки информации играет решающую роль в достижении стабильных результатов классификации и распознавания.

Современные тенденции развития классических подходов включают в себя использование методов регуляризации, алгоритмов оптимизации и техник понижения размерности, что позволяет повысить устойчивость моделей к шумам и снизить избыточность данных. Это делает возможным применение таких алгоритмов в условиях ограниченных вычислительных ресурсов и при работе с

большими объёмами информации. За счёт этого классические методы сохраняют практическую ценность в задачах, где важны интерпретируемость, быстрота обучения и возможность адаптации к экспериментальным условиям.

Следует подчеркнуть, что несмотря на стремительное развитие глубокого обучения, классические методы продолжают активно использоваться как в фундаментальных, так и в прикладных исследованиях. Они служат основой для построения более сложных архитектур, обеспечивая при этом простоту реализации и понимания. Их дальнейшее совершенствование, а также объединение с современными инструментами анализа данных способствует созданию адаптивных и надёжных систем, в том числе применимых в агропромышленном комплексе. Глубинные нейросетевые архитектуры представляют собой один из наиболее мощных инструментов современной аналитики, широко применяющийся в задачах, связанных с обработкой изображений, текстов, звука и других сложных форм данных. Их многоуровневая структура позволяет последовательно извлекать и интерпретировать признаки различной сложности — от базовых геометрических характеристик до высокоуровневых абстрактных представлений.

Ключевая особенность глубоких нейросетей — их способность к самостоятельному формированию признаков за счёт обучения на больших объёмах данных. В отличие от классических алгоритмов, где признаки задаются вручную, нейросети выявляют значимые закономерности в процессе итеративной настройки внутренних параметров, используя метод обратного распространения ошибки. Это позволяет минимизировать человеческое участие в формализации задачи и повысить гибкость модели при работе с разнородными источниками данных.

Глубокие сети эффективно справляются с моделированием сложных нелинейных зависимостей, что делает их особенно полезными в ситуациях, требующих высокой точности — например, при классификации изображений или анализе поведенческих паттернов. Использование различных функций активации позволяет моделям улавливать многоуровневые зависимости, которые трудно формализовать традиционными методами. В совокупности, всё это делает глубокие нейросети универсальным и мощным решением для широкого спектра аналитических задач, включая автоматизированный мониторинг и идентификацию животных в аграрной отрасли.

Практическое применение глубоких нейросетей сопряжено с необходимостью использования больших объёмов данных для обучения, что обеспечивает возможность выявления сложных закономерностей, присутствующих в обучающих выборках. В процессе обучения модели оптимизируют большое число параметров, что требует существенных вычислительных ресурсов, однако такие затраты окупаются за счёт значительного улучшения качества прогнозов и высокой адаптивности моделей к различным типам задач. Важным аспектом является также развитие методов регуляризации и оптимизации, способствующих снижению переобучения и повышению обобщающих способностей модели, что становится особенно актуальным при работе с динамично изменяющимися или зашумленными данными.

Научное сообщество продолжает активно исследовать теоретические и практические аспекты глубокого обучения, стремясь улучшить интерпретируемость моделей и повысить их устойчивость к вариациям во входных данных. Несмотря на то, что глубокие нейросети зачастую воспринимаются как «чёрные ящики», современные исследования направлены на разработку методов визуализации и анализа внутренних представлений модели, что позволяет получить более глубокое понимание процессов, происходящих в сети, и объяснить её решения. В совокупности данные подходы способствуют развитию гибких и адаптивных систем, способных работать в реальном времени и принимать решения на основе сложных многомерных данных, что является важным шагом на пути к созданию автономных интеллектуальных систем.

Глубокие нейросети представляют собой мощный инструмент, объединяющий достижения теории вероятностей, оптимизации и вычислительной математики, что позволяет им эффективно решать задачи, ранее считавшиеся крайне сложными для традиционных методов. Интенсивное развитие данной области сопровождается постоянным совершенствованием архитектурных решений, алгоритмов обучения и методов повышения устойчивости моделей, что открывает новые горизонты для их применения в широком спектре практических задач и способствует дальнейшему развитию теоретических основ искусственного интеллекта.

1.3.2 Компьютерное зрение

Компьютерное зрение представляет собой междисциплинарную область, объединяющую методы обработки изображений, алгоритмы анализа данных и современные подходы машинного обучения, направленные на автоматическое извлечение, интерпретацию и классификацию визуальной информации. Эта область науки и техники основывается на математических моделях и алгоритмах, позволяющих преобразовывать цифровые изображения в структурированные данные, пригодные для последующего анализа. В основе современных методов компьютерного зрения лежат алгоритмы, способные осуществлять детальное распознавание объектов, сегментацию изображений и выявление закономерностей, что способствует автоматизации процессов, ранее выполняемых исключительно человеком.

Применение компьютерного зрения в сельском хозяйстве открывает широкие перспективы для повышения эффективности и точности управления аграрными процессами [38; 43; 57; 61; 80]. Технологии, основанные на анализе изображений, позволяют помимо детекции животных, автоматизировать мониторинг состояния посевов, выявлять ранние признаки заболеваний растений и оценивать уровень их засухоустойчивости, что способствует оперативному принятию управленческих решений на сельскохозяйственных предприятиях. В области животноводства компьютерное зрение может быть использовано для идентификации индивидуальных животных, контроля их состояния и поведения, а также для автоматизации процессов кормления и ухода, что существенно снижает трудозатраты и повышает точность диагностики [51; 62]. Интеграция данных технологий в системы управления сельскохозяйственными предприятиями позволяет создать гибкие и адаптивные платформы, обеспечивающие высокую степень автоматизации и оптимизацию ресурсопотребления.

Научные исследования в области компьютерного зрения направлены на увеличение работоспособности системы в сложных условиях изменчивой среды, таких как освещенность, что особенно важно для применения в сельском хозяйстве. Разработка методов, обеспечивающих устойчивость к внешним возмущениям и вариативности входных данных, позволяет применять данные технологии в реальных условиях эксплуатации, где качество изображений может существенно колебаться. Применение методов глубокой обработки

изображений, таких как сверточные нейронные сети, обеспечивает высокую точность распознавания и классификации объектов, что открывает возможность для создания автономных систем мониторинга, способных в режиме реального времени оценивать состояние сельскохозяйственных культур и животных.

Компьютерное зрение становится неотъемлемым инструментом в современном сельском хозяйстве, способствуя повышению производительности, снижению операционных затрат и улучшению качества аграрной продукции. Современные разработки в этой области позволяют интегрировать анализ визуальных данных в комплексные системы управления, что способствует реализации концепций "Сельское хозяйство 4.0" и интеллектуального контроля за состоянием сельскохозяйственных объектов. Применение компьютерного зрения в аграрном секторе представляет собой важное направление исследований, направленных на повышение устойчивости и эффективности сельскохозяйственного производства, что в перспективе способствует развитию экологически чистых и высокопродуктивных систем агрономии. Современные методы компьютерного зрения играют важную роль в автоматизации задач мониторинга и анализа биологических объектов, среди которых особое место занимает детекция животных. В условиях динамично изменяющейся окружающей среды, характеризующейся разнообразием фонов, вариативностью освещенности и сложной структурой сцены, традиционные алгоритмы зачастую не способны обеспечить необходимую точность и скорость обработки данных. В этой связи сверточные нейронные сети (CNN) демонстрируют высокую эффективность за счет способности автоматически извлекать и иерархически представлять признаки изображений, что позволяет значительно улучшить показатели детекции.

Сверточные нейронные сети представляют собой особый класс моделей глубокого обучения, в основе которых лежат сверточные операции, направленные на извлечение локальных признаков из входных данных. Такие сети обучаются выделять релевантные особенности, начиная с низкоуровневых признаков, таких как края и текстуры, и переходя к более сложным паттернам, характерным для конкретных объектов, формируют представление об изображении, достаточное для выполнения задачи детекции, классификации и локализации объектов. В условиях сложной окружающей среды, где объекты могут быть частично закрыты, искажены или иметь нечеткие границы, способность CNN к иерархическому извлечению признаков становится ключевым преимуществом.

Одним из наиболее популярных представителей современных архитектур является модель YOLO («You Only Look Once»), которая реализует концепцию единственного прохода по изображению для одновременного решения задач классификации и локализации объектов. Особенностью данной архитектуры является высокая скорость обработки за счет прямого прогнозирования координат ограничивающих рамок и соответствующих вероятностей классов, что делает ее пригодной для реализации систем реального времени. YOLO демонстрирует высокую эффективность при обработке изображений, полученных в производственных условиях, где требуется оперативная реакция на изменение ситуации.

Альтернативным подходом является архитектура Faster R-CNN, представляющая собой двухэтапную систему, в которой первый этап выполняет генерацию гипотез о местонахождении объектов посредством использования сети для формирования областей внимания модели, а второй этап отвечает за уточнение координат рамок и проведение классификации. Данный метод, хотя и требует больших вычислительных затрат по сравнению с одношаговыми системами, позволяет добиться высокой точности детекции, что особенно важно при анализе изображений с высоким уровнем сложности и "шумов" характерных для животноводческих предприятий.

Новейшие разработки в области сверточных нейронных сетей привели к появлению архитектур, таких как EfficientDet, которые стремятся объединить преимущества высокой точности и эффективности вычислений. EfficientDet использует модульную структуру, включающую в себя многоуровневую обработку признаков посредством двунаправленного пирамидального сетевого слоя (BiFPN), что позволяет оптимально сочетать информацию, полученную на различных масштабах изображения. Такая архитектура демонстрирует превосходные результаты при решении задач детекции в сложных условиях, когда требуется баланс между скоростью работы модели и качеством прогнозов.

Применение описанных моделей для детекции животных позволяет решать широкий спектр практических задач. Использование CNN в аграрном секторе предоставляет возможность автоматизированного контроля за состоянием животных, выявления ранних признаков заболеваний и мониторинга поведения, что в совокупности способствует оптимизации управленческих процессов и снижению затрат на содержание поголовья. Благодаря способности моделей обрабатывать изображения, полученные в условиях переменной освещенности, изменяющегося фона и наличия помех, современные системы на

базе YOLO, Faster R-CNN и EfficientDet могут эффективно функционировать в реальном времени и обеспечивать высокую точность обнаружения даже при наличии сложных визуальных условий.

В научном контексте детекция животных с использованием сверточных нейронных сетей требует тщательного подхода к выбору архитектуры, настройки гиперпараметров и формирования обучающих выборок, учитывающих вариативность окружающей среды, а также грамотный подход к дистилляции моделей, для их внедрения в промышленную эксплуатацию. При этом важным аспектом является обеспечение достаточного количества репрезентативных данных, позволяющих моделям обучаться на широком диапазоне сценариев, включая изменение ракурса, масштабов и освещенности. Оптимизация модели также включает применение методов регуляризации и адаптивных алгоритмов обучения, что способствует снижению риска переобучения и повышению обобщающих способностей сети.

Использование сверточных нейронных сетей, таких как YOLO, Faster R-CNN и EfficientDet, представляет собой перспективное направление в области компьютерного зрения, позволяющее решать задачи детекции животных с высокой степенью точности и оперативности. Интеграция этих методов в комплексные системы мониторинга может способствовать существенному улучшению процессов управления в сельском хозяйстве. Одним из перспективных направлений является применение ИИ-алгоритмов для анализа инфракрасных изображений, что обеспечивает возможность детектирования и идентификации животных посредством анализа излучения инфракрасных меток, установленных на их теле. Данный подход основывается на регистрации и спектральном анализе инфракрасного света, испускаемого метками, что позволяет определить уникальный идентификатор, соответствующий определенной длине волны излучения.

Первоначальной стадией данного метода является получение инфракрасных изображений с использованием специализированных камер, способных фиксировать диапазон волн, недоступный для человеческого глаза. Такие камеры регистрируют тепловое излучение и инфракрасные сигналы, что обеспечивает возможность обнаружения меток, даже при сложных условиях окружающей среды, таких как низкая освещенность или наличие визуальных помех. Преимущество инфракрасного подхода заключается в том, что он позволяет получать качественные изображения объектов, независимо от внешних

оптических условий, что является особенно важным при мониторинге животных на животноводческих предприятиях.

Следующим этапом является обработка полученных изображений с применением алгоритмов глубокого обучения и методов компьютерного зрения. Современные ИИ-алгоритмы способны выполнять автоматическую сегментацию изображений, выделяя области, содержащие инфракрасные метки, и проводить анализ спектральных характеристик каждого выделенного объекта. Использование сверточных нейронных сетей в данной задаче позволяет не только детектировать присутствие меток, но и классифицировать их по специфическим спектральным характеристикам. При этом каждая метка, излучающая свет на определенной длине волны, ассоциируется с уникальным идентификатором, что обеспечивает возможность точной идентификации конкретного животного.

Ключевым элементом методологии является спектральный анализ, который позволяет дискретизировать диапазон инфракрасного излучения и сопоставлять наблюдаемые длины волн с predetermined значениями, характеризующими отдельные метки. Это достигается посредством применения алгоритмов, осуществляющих быструю и точную калибровку полученных данных, что позволяет минимизировать погрешности при определении спектральных характеристик. В результате такой подход позволяет создавать базы данных, в которых каждому животному присваивается уникальный идентификатор, определяемый по длине волны излучения, что значительно упрощает процессы мониторинга, учета и анализа динамики популяций.

Практическая реализация описанной методики требует интеграции различных технических решений, включая высокоточные инфракрасные камеры, системы хранения и обработки больших объемов данных, а также программное обеспечение для реализации алгоритмов машинного обучения. Современные вычислительные платформы и технологии облачных вычислений позволяют осуществлять обработку данных в режиме реального времени, что особенно актуально для систем мониторинга животных. Интеграция данного подхода в систему управления сельскохозяйственными объектами способствует не только повышению точности идентификации животных, но и позволяет оптимизировать процессы контроля за состоянием поголовья, прогнозирования заболеваний и оперативного реагирования на изменения в поведении животных.

Анализ инфракрасных изображений с применением ИИ-алгоритмов представляет собой комплексное междисциплинарное направление, объединяющее достижения физики, спектральной аналитики, обработки изображений и машинного обучения. Разработка и внедрение таких систем позволяет значительно расширить возможности автоматизированного мониторинга животных, обеспечивая высокую точность идентификации даже в условиях сложной окружающей среды. В перспективе дальнейшее совершенствование алгоритмов и увеличение точности спектрального анализа будет способствовать развитию более эффективных и адаптивных систем наблюдения, что окажет существенное влияние на повышение производительности и устойчивости сельскохозяйственных предприятий [111], а также на сохранение биоразнообразия в естественных экосистемах.

Таким образом, использование технологий искусственного интеллекта в задаче детекции животных позволяет повысить точность и эффективность автоматизированных систем идентификации. В частности, сочетание инфракрасного анализа и глубокого обучения представляет собой перспективное направление для создания надежных и масштабируемых решений в сельском хозяйстве.

1.4 Анализ технологии инфракрасной идентификации и оценка перспектив использования в АПК

Инфракрасная идентификация — это технология, которая использует инфракрасное излучение для распознавания и отслеживания объектов. В агропромышленном комплексе такая технология может быть применена для идентификации животных, автоматизации процессов управления и повышения эффективности производства [103]. В этом разделе рассмотрим, как работает ИК-идентификация, её преимущества и недостатки, а также перспективы использования в сельском хозяйстве.

При использовании разработанной системы каждое животное получает уникальную ИК-метку, которая излучает сигнал определенной частоты. Этот сигнал улавливается специальным приемником, который распознает метку и

идентифицирует животное. К преимуществам ИК-излучения можно отнести, следующие свойства:

- Хорошо распространяется в воздухе.
- Не проходит через стены, что позволяет использовать одинаковые метки в соседних помещениях без взаимных помех.
- Безопасно для животных и людей, так как не оказывает вредного воздействия.
- Низкая стоимость: ИК-метки дешевле в производстве по сравнению с другими технологиями, такими как RFID или чипирование.
- Безопасность: ИК-излучение не причиняет вреда животным и не вызывает у них стресса.
- Простота использования: ИК-метки легко устанавливаются и не требуют сложного обслуживания.
- Автоматизация: ИК-системы позволяют автоматизировать процессы идентификации и мониторинга, что снижает трудозатраты и повышает точность учета.
- Локальность действия: ИК-метки работают только в пределах помещения, что исключает помехи от соседних систем.

Но у выбранного спектра также есть и недостатки, которые необходимо учитывать:

- Ограниченная дальность действия: ИК-сигналы работают на коротких расстояниях, что делает их менее подходящими для использования на открытых пространствах.
- Зависимость от инфраструктуры: для работы ИК-системы необходимо установить приемники и программное обеспечение, что может быть затратно для небольших хозяйств.
- Чувствительность к помехам: пыль, туман или другие препятствия могут ухудшать качество сигнала.

Инфракрасная идентификация обладает значительным потенциалом для применения в различных отраслях агропромышленного комплекса. Её использование может значительно повысить эффективность управления животноводческими предприятиями, улучшить контроль за состоянием животных и автоматизировать ключевые процессы. Рассмотрим ключевые направления применения этой технологии.

Одной из основных задач в животноводстве является точный учет поголовья. ИК-идентификация позволяет решить эту проблему, обеспечивая уникальную маркировку для каждого животного. Это помогает вести учет, отслеживать возраст, породу и историю вакцинации. Кроме того, система контролирует перемещение животных между загонами и пастбищами, что критически важно для крупных ферм. В племенных хозяйствах эта технология играет ключевую роль, обеспечивая точное отслеживание родословных для селекционной работы.

Следующим шагом является интеграция ИК-технологий в автоматизированные системы управления, что упрощает процессы и повышает их точность. Помимо учетных и автоматизированных задач, ИК-идентификация служит мощным инструментом для мониторинга состояния животных. Система фиксирует изменения в двигательной активности, которые часто являются первым признаком проблем со здоровьем, позволяя оперативно реагировать. Раннее выявление болезней по поведенческим изменениям особенно важно на птицефермах с их высоким риском распространения инфекций. Технология также позволяет более пристально наблюдать за беременными животными (стельными коровами, супоросными свиноматками и др.), своевременно организовывая ветеринарную помощь и снижая риски при родах.

Наконец, ИК-идентификация выходит за пределы отдельной фермы, способствуя повышению прозрачности во всей логистической цепи. Она обеспечивает прослеживаемость происхождения продукции, позволяя точно установить, от какого животного получено мясо, молоко или шерсть, что крайне важно для сертификации качества и санитарной безопасности. Кроме того, система позволяет отслеживать перемещение животных во время транспортировки, минимизируя потери и снижая риски нарушения ветеринарных норм.

Для удобства все основные направления применения ИК-идентификации в АПК сведены в таблицу 1.2.

Таким образом, инфракрасная идентификация является многофункциональным инструментом, который не только решает узкие задачи учета, но и комплексно преобразует управление современным агропромышленным комплексом, делая его более точным, эффективным и прозрачным.

Однако ИК-идентификация подходит не для всех случаев. Например, на крупных фермах с открытыми пастбищами более эффективными могут быть RFID-метки или чипирование.

Таблица 1.2 — Направления применения ИК-идентификации в АПК

Направление применения	Конкретные задачи и преимущества
Идентификация и учет животных	– Уникальная маркировка – Контроль перемещений – Ведение племенного учета и родословных
Автоматизация процессов	– Автоматизация доения – Контроль кормления – Автоматическая сортировка по весу и состоянию
Мониторинг состояния животных	– Отслеживание активности для выявления болезней – Раннее обнаружение патологий – Контроль за беременными животными
Управление логистикой и происхождением	– Прослеживаемость происхождения продукции (мясо, молоко) – Контроль перемещений при транспортировке – Обеспечение санитарной безопасности

Таким образом, инфракрасная идентификация — это перспективная технология, которая может значительно улучшить процессы управления в агропромышленном комплексе. Её преимущества, такие как низкая стоимость, безопасность и возможность автоматизации, делают её привлекательной для использования на сельскохозяйственных предприятиях. Однако для успешного внедрения необходимо учитывать ограничения, такие как короткая дальность действия и зависимость от инфраструктуры. В целом, ИК-идентификация может стать важным инструментом для повышения эффективности и прозрачности бизнес процессов в сельском хозяйстве.

1.5 Выводы по главе

Актуальность исследования применения современных методов искусственного интеллекта в задачах детекции и идентификации животных обусловлена необходимостью повышения эффективности мониторинга и управления сельскохозяйственными и природоохранными объектами [18; 22; 23]. Проведённый анализ классических методов машинного обучения, глубоких нейросетевых подходов, компьютерного зрения и спектрального анализа инфракрасных изображений демонстрирует, что интеграция этих технологий позволяет значительно улучшить точность, скорость и устойчивость детекционных систем в условиях изменчивой окружающей среды.

Классические алгоритмы, несмотря на свою зависимость от ручного отбора признаков, остаются важным инструментом для построения интерпретируемых моделей, что особенно актуально при ограниченных вычислительных ресурсах (до 2–4 ГБ ОЗУ и 1–2 ядра CPU) и необходимости объяснения полученных результатов. Современные методы глубокого обучения, в частности, сверточные нейронные сети, обеспечивают высокую точность (до 95–98%) и адаптивность при обработке сложных визуальных данных, позволяя эффективно решать задачи локализации и классификации объектов в реальном времени (до 30–60 кадров/с при разрешении 1280×720 пикселей).

Особое значение приобретает применение специализированных архитектур, таких как YOLOv8, Faster R-CNN и EfficientDet-D3, способных работать в условиях сильных помех, изменяемого фона и переменной освещённости (в диапазоне 50–5000 лк). Их использование в аграрном секторе и системах охраны природы позволяет не только повысить качество мониторинга животных (точность идентификации до 92–97%), но и оптимизировать управленческие решения за счёт оперативного обнаружения и идентификации объектов с задержкой не более 100–150 мс.

Анализ инфракрасных изображений с применением ИИ-алгоритмов для идентификации животных по спектральным характеристикам меток демонстрирует новые возможности в области автоматизированного мониторинга сельскохозяйственных животных. Спектральный анализ позволяет создавать системы, способные определять уникальные идентификаторы животных по из-

лучаемой длине волны, что особенно важно при работе в условиях низкой освещенности или при наличии визуальных помех.

Таким образом, актуальность рассматриваемого направления определяется его потенциалом для создания высокоадаптивных, точных и автоматизированных систем мониторинга [13], способных удовлетворить требования современного сельского хозяйства. Интеграция классических и современных методов обработки изображений, алгоритмов машинного обучения и глубокого анализа данных открывает перспективы для дальнейших исследований и практического внедрения инновационных решений, что способствует оптимизации управления, снижению затрат и повышению эффективности контроля за состоянием животных в различных производственных условиях.

Глава 2. Теоретические исследования

2.1 Обоснование технологической применимости инфракрасной системы идентификации сельскохозяйственных животных

Явление дисперсии света [35; 37; 63] обусловлено вынужденными колебаниями заряженных частиц под воздействием переменного электромагнитного поля [41]. Все электроны, входящие в состав атома, можно разделить на периферийные (оптические) и электроны внутренних оболочек. Как известно, электроны — это фермионы, которые подчиняются распределению Ферми-Дирака и принципу запрета Паули [35]. Таким образом, электроны имеют всегда определенную энергию покоя и обязаны переходить в возбужденное состояние только при поглощении энергии, где величина определяется точным решением уравнения Шредингера [35]:

$$i\hbar \frac{\partial \Psi(\mathbf{r}, t)}{\partial t} = \hat{H} \Psi(\mathbf{r}, t), \quad (2.1)$$

где:

- i — мнимая единица,
- $\hbar$ — редуцированная постоянная Планка,
- $\Psi(\mathbf{r}, t)$ — волновая функция, зависящая от координат $\mathbf{r}$ и времени t ,
- $\hat{H}$ — гамильтониан системы, оператор полной энергии.

Для каждого атома величины n свои. При этом важно учитывать, что в оптическом диапазоне спектра излучение и поглощение света обусловлены исключительно оптическими электронами, поскольку собственные частоты электронов внутренних оболочек слишком высоки [50]. В классической теории дисперсии [41] электрон рассматривается как гармонический осциллятор, колебания которого в поле электромагнитной волны описываются уравнением:

$$m \frac{d^2 x}{dt^2} + \gamma \frac{dx}{dt} + kx = -eE(t), \quad (2.2)$$

где:

- m — масса электрона,
- e — заряд электрона,

- γ — коэффициент затухания,
- k — коэффициент квазиупругой силы,
- $E(t)$ — напряженность электрического поля, действующего на электрон.

Корректная теория дисперсии света опирается на квантовые законы, но приводит к следующему выводу: с точки зрения дисперсии и поглощения света атомы ведут себя так, словно среда состоит из множества осцилляторов с разными собственными частотами и коэффициентами затухания, которые описываются классическим уравнением движения. Следовательно, применение такого приближения оказывается вполне обоснованным. Однако собственные частоты не могут быть вычислены на основе классической модели и вычисляются только благодаря применению квантовой теории. Для нахождения собственных частот необходимо решение уравнения Шредингера [41].

В инфракрасной области спектра [44] основную роль играют свободные электроны и ионы вблизи их собственных частот. Выбор ИК-диапазона для изобретения более дешевого и надежного способа идентификации [112] обусловлен особенностями явления дисперсии в выбранном диапазоне. Как известно [41], зависимость показателя преломления от частоты для большинства веществ выражается следующей формулой:

$$n(\omega) = 1 + \frac{e^2}{2\varepsilon_0 m} \sum_j \frac{N_j}{\omega_j^2 - \omega^2 - i\gamma_j \omega}, \quad (2.3)$$

где:

- $n(\omega)$ — показатель преломления,
- e — заряд электрона,
- ω — частота излучения,
- m — масса электрона,
- N_j — плотность электронов с частотой ω_j в единице объема и коэффициентом затухания γ_j .

Из формулы (2.3) видно, что показатель преломления является комплексной величиной и представляется в виде:

$$n(\omega) = n'(\omega) + in''(\omega), \quad (2.4)$$

где:

- $n'(\omega)$ и $n''(\omega)$ — вещественные части.

Как известно [35], при таком представлении $n''(\omega)$ является коэффициентом поглощения. Обычно (как у стекла и видимого спектра излучения) поглощение света очень мало, что видно из формулы (2.3), так как $n''(\omega) \ll n'(\omega)$. Однако при приближении к резонансной частоте мнимое слагаемое становится преобладающим, что означает сильное поглощение. Например, солнечное излучение, проходящее через атмосферу, сильно поглощается в резонансных частотах атомов, входящих в состав атмосферы, и как следствие в спектре наблюдаются темные линии. Необходимо выбрать такой диапазон, чтобы с одной стороны излучение хорошо распространялось в воздухе, но при этом было бы непроницаемым сквозь бетонные стены помещений.

Таким образом, показатель преломления выражается через атомные постоянные и также зависит от частоты излучения. Для нахождения резонансных частот необходимо знать собственную частоту атомов, из которых состоит вещество, и число атомов в единице объема. Общая теория свойств и собственных частот формируется на основе квантовой механики. У большинства газов, включая воздух вблизи земной поверхности и многие бесцветные газы, такие как водород, гелий и другие, колебания электронов имеют собственные частоты, которые находятся в ультрафиолетовом диапазоне. Это означает, что их взаимодействие с излучением происходит преимущественно в этой области спектра, что влияет на их оптические свойства и поведение в различных условиях. Эти частоты много больше выбранного диапазона в ИК-спектре, следовательно, $n(\omega)$ можно считать практически константным.

Основываясь на формуле (2.3), можно сделать выводы о поглощающей способности объектов в выбранном диапазоне частот. Таким образом, выбирается ближний спектр ИК-излучения в диапазоне от 700 нм до 1500 нм. Именно в этом диапазоне получаем необходимые для целей исследования свойства излучения:

- Хороший коэффициент отражения от большинства материалов, находящихся в помещении (стен, мебели).
- Хорошую пропускную способность в воздухе.
- Малое рассеяние внутри помещения.
- Практически нулевую проникающую способность сквозь бетонные стены.

Следовательно, выбранный диапазон не только очень прост и дешев в применении и изготовлении идентификационных меток, но также позволяет

использовать одинаковые метки в соседних помещениях, что значительно удешевляет производство.

Для создания универсальной системы идентификации предлагается рассмотреть следующие варианты инфракрасных излучателей:

- Инфракрасные светодиоды (IR LED) — излучают видимый свет с длиной волны в инфракрасном диапазоне. Применяются в различных ИК-системах, таких как ИК-камеры, ИК-датчики, ИК-передатчики и т.д.
- Лавинные фотодиоды (LPD) — это быстродействующие фотодиоды с лавинным пробоем. Они обладают высокой скоростью переключения и малым временем нарастания. Применяются в ИК-системах для высокоскоростной передачи данных.
- Фотодиоды на основе HgCdTe (МСТ) — это фотодиоды на основе материала HgCdTe, который обладает высоким коэффициентом поглощения в ИК-диапазоне. Применяются в высокочувствительных ИК-системах.
- Фототранзисторы на основе InGaAs (IGT) — это транзисторы на основе материала InGaAs, который имеет высокий коэффициент поглощения в ИК-диапазоне и малое время переключения. Применяются в высокоскоростных ИК-системах и в датчиках изображения.
- Горизонтальные фототранзисторы (НРТ) — это горизонтальные фототранзисторы с высоким коэффициентом усиления и малым уровнем шума. Применяются в высококачественных ИК-системах с высоким разрешением.

Для решения задачи идентификации лучше всего подходят инфракрасные светодиоды (IR LED), так как они дешевы и имеют необходимый для работы диапазон длин волн.

Таким образом, мы получаем хорошую разрешающую способность каждой метки и возможность использования одинаковых меток в соседних помещениях, низкую стоимость производства в сравнении с микрочипами, без вреда здоровью и причинения стресса животным. Однако стоит отметить, что ИК-метки имеют и недостатки:

- Необходимость монтирования специального оборудования с ИК-приемником.
- Необходимость разработки дополнительного программного обеспечения на основе искусственного интеллекта и компьютерного зрения.

Инфракрасная (ИК) идентификация животных обладает рядом преимуществ по сравнению с другими существующими методами, такими как биркование, чипирование, RFID-метки и визуальные методы. Однако её эффективность и применимость зависят от конкретных условий использования. Далее проведем подробное сравнение ИК-идентификации с другими методами.




Рисунок 2.1 — Сравнительная характеристика методов идентификации животных

На диаграмме 2.1 представлено сравнение различных методов идентификации по ключевым параметрам. ИК-метки демонстрируют хороший баланс между стоимостью, безопасностью и точностью, что делает их привлекательным решением для многих сценариев использования.

Радарная диаграмма на рисунке 2.2 наглядно показывает сильные и слабые стороны каждого метода. Сравнение производится на основе экспертной оценки представителей отрасли по шкале от 1 до 5. ИК-идентификация выделяется высокими показателями безопасности и хорошей точностью при умеренной стоимости.

Инфракрасная идентификация животных обладает рядом преимуществ по сравнению с другими методами, такими как безопасность, низкая стоимость и возможность автоматизации процессов.




Рисунок 2.2 — Радарная диаграмма сравнения методов идентификации

Инфракрасная идентификация обладает значительным потенциалом для применения в агропромышленном комплексе. Её преимущества, такие как низкая стоимость, безопасность для животных и возможность использования в соседних помещениях, делают её привлекательной для автоматизации процессов на фермах. Однако для успешного внедрения необходимо решить вопросы, связанные с разработкой специализированного оборудования и программного обеспечения. В целом, инфракрасная идентификация может стать эффективным инструментом для повышения производительности и контроля в АПК.

2.2 Обоснование технологической применимости искусственного интеллекта

Применение искусственного интеллекта в задаче детекции сельскохозяйственных животных обосновано многолетним успешным опытом использования подобных технологий в ряде других областей, где требования к точности, скорости обработки данных и устойчивости алгоритмов уже доказали свою эффективность. Нейронные сети, в частности свёрточные архитектуры, успешно применяются для распознавания лиц в системах видеонаблюдения, что демонстрирует их способность выделять характерные признаки объектов даже в

условиях изменяющегося освещения и сложного фона. Этот опыт наглядно подтверждает, что алгоритмы могут быть адаптированы для анализа изображений сельскохозяйственных животных, у которых также присутствует значительное разнообразие внешних характеристик.

Ещё одним успешным примером является применение ИИ в медицине, в частности в анализе снимков магнитно-резонансной томографии (МРТ) и компьютерной томографии (КТ). Искусственный интеллект демонстрирует высокую эффективность глубоких нейронных сетей для выявления патологических изменений. Современные алгоритмы, основанные на свёрточных нейронных сетях, обучаются на обширных наборах данных медицинских изображений, что позволяет им обнаруживать тонкие структурные отклонения в тканях, свидетельствующие о ранних стадиях заболевания. Эти методы способны идентифицировать даже незначительные изменения, которые могут быть незаметны при традиционном визуальном анализе, что существенно повышает диагностическую точность и способствует своевременному принятию лечебных мер.

Такой междисциплинарный опыт указывает на возможность адаптации аналогичных методик для мониторинга состояния здоровья сельскохозяйственных животных или для задачи детекции. В аграрном секторе, как и в медицине, необходимо своевременно выявлять начальные признаки патологических процессов для предотвращения масштабных убытков и ухудшения состояния поголовья. Алгоритмы, разработанные для анализа сложных медицинских изображений, могут быть переобучены для работы с визуальными данными животных, позволяя обнаруживать ранние изменения в поведении или физиологическом состоянии, которые предшествуют развитию заболеваний. Такой подход обеспечит создание интегрированных систем раннего предупреждения и мониторинга, способных повысить общую эффективность управления животноводческими хозяйствами и минимизировать влияние негативных факторов на продуктивность.

Применение ИИ в медицинской диагностике демонстрирует, что методы глубокого обучения обладают достаточной чувствительностью и адаптивностью для работы с разнообразными и сложными изображениями [91; 94]. Перенос этих технологий в аграрный сектор открывает перспективы для разработки систем детекции патологических состояний у животных, что позволит суще-

ственно повысить точность мониторинга и эффективность профилактических мероприятий в животноводстве.

Опыт применения искусственного интеллекта в системах автономного вождения демонстрирует, что современные методы могут эффективно справляться с задачами детекции объектов в режиме реального времени даже при наличии многомодальных данных. В системах автономного транспорта данные с видеокамер, лидаров и радаров интегрируются для получения точной пространственной информации об окружающей среде. Алгоритмы глубокого обучения, в частности свёрточные нейронные сети, обучаются на обширных выборках данных, что позволяет им надежно распознавать пешеходов, транспортные средства и препятствия в условиях динамически меняющейся дорожной обстановки. Высокая скорость обработки и адаптивность этих алгоритмов обеспечиваются за счет параллельных вычислений и использования специализированных аппаратных средств, что позволяет системе непрерывно контролировать ситуацию и оперативно реагировать на возникновение потенциально опасных ситуаций.

Аналогичные принципы можно применить для мониторинга состояния сельскохозяйственных животных. Как и в автономном вождении, задача мониторинга в аграрном секторе требует интеграции информации с различных сенсоров – видеокамер, инфракрасных датчиков и других устройств – для своевременного обнаружения изменений в поведении или физиологическом состоянии животных. Многоканальный анализ данных позволяет системе корректно интерпретировать поступающую информацию даже в условиях сложного фона или изменяющейся окружающей среды. Такой подход обеспечивает не только высокую точность детекции, но и возможность оперативного реагирования на выявленные аномалии, что критически важно для предотвращения распространения заболеваний и оптимизации управления животноводческими процессами.

Опыт использования искусственного интеллекта в автономном вождении служит убедительным аргументом для его применения в задачах мониторинга в аграрном секторе. Интеграция данных с различных сенсоров, высокая надежность алгоритмов глубокого обучения и возможность непрерывного контроля создают прочную основу для разработки систем, способных своевременно фиксировать изменения в состоянии животных и обеспечивать автоматизированное управление процессами в сельском хозяйстве.

Применение искусственного интеллекта в промышленном контроле качества является ярким примером высокотехнологичного подхода к обнаружению микроскопических дефектов в производственных процессах. Современные системы визуального контроля, основанные на алгоритмах глубокого обучения, обучаются на обширных выборках изображений, что позволяет им распознавать даже минимальные отклонения от стандартных параметров. Эти алгоритмы демонстрируют высокую чувствительность при выявлении тонких изменений, которые могут свидетельствовать о ранних признаках брака продукции. Анализ изображений осуществляется с использованием методов компьютерного зрения, позволяющих выделять аномалии в текстуре, форме или цветовой гамме объектов, что существенно повышает точность детекции и обеспечивает надежное качество контроля.

Подобные методики находят прямое отражение в задаче мониторинга состояния сельскохозяйственных животных [60]. Как и в промышленном контроле качества, раннее выявление незначительных отклонений от нормы может свидетельствовать о появлении патологических состояний или аномалий в поведении. Адаптация методов детекции, успешно применяемых в производстве, к аграрному сектору позволяет автоматизировать процессы наблюдения и анализа данных, получаемых с камер наблюдения или других сенсорных устройств. Это, в свою очередь, способствует оперативному выявлению первых симптомов заболеваний или стресса у животных, что является критически важным для предотвращения дальнейшего ухудшения их состояния и минимизации экономических потерь.

Кроме того, применение методов глубокого обучения для анализа изображений позволяет снизить вероятность ошибок, связанных с субъективной оценкой состояния животных, и уменьшить зависимость от человеческого фактора. Автоматизированные системы, способные в реальном времени анализировать поступающие данные, обеспечивают непрерывный мониторинг, что особенно актуально в условиях крупных животноводческих комплексов. Таким образом, междисциплинарный опыт в области промышленного контроля качества демонстрирует, что адаптация современных технологий ИИ к аграрным задачам имеет высокую научную и практическую обоснованность, способствуя оптимизации процессов мониторинга и повышению эффективности управления здоровьем животных.

Таким образом, широкий спектр успешных примеров [7; 17; 32] применения искусственного интеллекта в таких областях, как системы видеонаблюдения, медицинская диагностика, автономное вождение и промышленный контроль качества, подтверждает его высокую технологическую применимость для детекции сельскохозяйственных животных. Эти примеры демонстрируют, что современные алгоритмы способны работать с разнообразными, динамичными и часто "шумными" данными, обеспечивая высокую точность, скорость обработки и адаптивность к различным условиям. Научный и практический опыт из других сфер служит прочной базой для уверенного внедрения технологий ИИ в аграрном секторе, что позволяет эффективно решать задачи мониторинга, диагностики и управления состоянием животных в современных сельскохозяйственных системах.

2.3 Методология сбора обучающего датасета для обучения моделей искусственного интеллекта

Задача сбора датасета для обучения нейронных сетей нацелена на создание репрезентативной выборки изображений и видео, позволяющей повысить точность детектирования объектов и идентификации отдельных субъектов с применением алгоритмов компьютерного зрения. Особое внимание уделено двум основным направлениям: разметке стандартного видеодатасета с использованием сервиса `cvat.ai` для обучения моделей семейства YOLO и разметке датасета с инфракрасной камеры [98].

Процесс разметки видеодатасета был организован с учетом специфических требований для обучения детекционных моделей, что позволило оптимизировать работу алгоритмов семейства YOLO. Основным инструментом для высокоточной ручной аннотации выступал сервис `cvat.ai`, который обеспечивал корректное выделение объектов в каждом кадре видеоматериала. Благодаря такому подходу удалось создать условия для оперативного взаимодействия между специалистами в области компьютерного зрения и зоотехнии, что способствовало интеграции практического опыта специалистов сельского хозяйства в процесс формирования обучающих выборок. При этом, особое внимание уделялось не только техническим аспектам разметки, но и качеству, достоверности и

консистентности получаемых аннотаций, что является важным фактором для повышения точности детекторов.

Для расширения возможностей разметки и ускорения процесса формирования датасета дополнительно был использован сервис Яндекс Толока. Применение различных инструментов для разметки данных позволило организовать масштабное распределение задач по аннотации, что способствовало оперативной предварительной разметке данных. Такой подход был особенно полезен на начальном этапе, когда требовалось быстро создать объемную выборку для дальнейшей валидации и корректировки экспертами в области компьютерного зрения. В результате, совместное использование `svat.ai` и Яндекс Толоки позволило обеспечить баланс между качественной ручной аннотацией и масштабируемостью процессов, что является важным аспектом при работе с большими объемами данных.

В рамках реализованной методологии был сформирован датасет, состоящий из 3000 изображений, полученных путем создания скриншотов из видео на реальном производстве. Примеры получившихся скриншотов представлены на рисунках 2.3, 2.4



Рисунок 2.3 — Пример изображения для обучения модели детекции с производства

На этих изображениях были зафиксированы животные, являющиеся объектами детекции в контексте задач компьютерного зрения. Процесс форми-



Рисунок 2.4 — Пример изображения для обучения модели детекции с производства

рования выборки включал предварительный этап извлечения ключевых кадров из видеопотока, что позволяло существенно сократить избыточность данных и сфокусироваться на наиболее информативных изображениях. Такой подход позволял минимизировать нагрузку на операторов, выполняющих аннотацию, и обеспечивал возможность более детального рассмотрения каждого кадра с точки зрения специфики визуального представления объектов.

Особое внимание уделялось синхронизации данных, полученных из различных источников. Разметка видеодатасета и инфракрасного материала проводилась с учетом специфики каждого типа данных, что позволяло добиться высокой согласованности между разными наборами информации. В случае с инфракрасными изображениями, где основное внимание уделялось идентификации отдельных особей посредством уникальных инфракрасных меток, методика разметки предусматривала не только выделение контуров объектов, но и точное определение положения меток. Это позволило проводить межкадровую корреляцию и создавать возможность отслеживания динамики перемещений животных в режиме реального времени, что имеет важное значение для мониторинга состояния сельскохозяйственных объектов в сложных условиях наблюдения.

Применение сервиса `svat.ai` для детальной аннотации видеоданных обеспечило высокую точность разметки, что в совокупности с использованием Яндекс Толоки позволило создать комплексную обучающую выборку, удовлетворяющую требованиям современных детекционных моделей. Такой двойной подход, сочетающий централизованный контроль качества и массовую предварительную аннотацию, способствовал устранению возможных ошибок, связанных с субъективностью отдельных операторов, и обеспечил стандартизацию процесса разметки. Благодаря интеграции множественных источников и платформ, методология позволила создать репрезентативный и масштабируемый датасет, способный удовлетворить требования обучения современных алгоритмов искусственного интеллекта.

Комплексность подхода позволила не только решить задачу формирования обучающей выборки, но и заложить основу для дальнейших исследований, направленных на оптимизацию процессов аннотации и адаптации моделей искусственного интеллекта к специфическим условиям аграрной среды. Полученные данные являются достаточным ресурсом для обучения и валидации алгоритмов детектирования, способных эффективно работать в режиме реального времени. Предложенная методология сбора обучающего датасета для исследования демонстрирует синтез передовых технологий компьютерного зрения и современных платформ для массовой разметки данных. Систематизированный процесс аннотации, основанный на использовании `svat.ai` и Яндекс Толоки, позволил создать высококачественную выборку из 3000 изображений, представляющих собой скриншоты из видеоматериалов с изображением животных.

Дополнительно проводилась разметка данных, полученных с инфракрасной камеры, что позволяло учитывать специфические особенности сельскохозяйственных животных в условиях ограниченной видимости и низкой освещенности. Данная методология основывалась на применении инфракрасных меток, каждая из которых имела уникальный идентификатор, что позволяло проводить автоматическую идентификацию отдельных особей в режиме реального времени. Процесс аннотирования инфракрасных изображений предусматривал выделение не только общих контуров объектов, но и детальную разметку локализованных участков, на которых фиксировались инфракрасные метки. Такой подход обеспечивал возможность не только обнаружения, но и дальнейшей идентификации объектов, что имеет важное значение для мони-

торинга состояния сельскохозяйственных культур и животных. Использование уникальных идентификаторов в инфракрасном спектре позволило проводить межкадровую корреляцию и повышать точность моделей, способных различать объекты с учетом их индивидуальных характеристик инфракрасного спектра.

Используемая методология сбора обучающего датасета объединяет классический подход к аннотированию видеоматериалов с современными технологиями инфракрасной съемки, что позволяет получать высококачественные данные для обучения моделей искусственного интеллекта. Систематизированный процесс разметки с использованием `svat.ai` в сочетании с детальной аннотацией инфракрасных изображений создает основу для дальнейшего обучения моделей искусственного интеллекта, направленных на повышение эффективности мониторинга и управления аграрными объектами.

2.4 Методология выбора подходящей базовой модели искусственного интеллекта

Для наиболее качественного решения задачи детекции особое внимание было уделено выбору подходящей модели искусственного интеллекта [40; 89; 113]. Исследование охватывало широкий спектр современных архитектур [85; 95], включающих как классические сверточные нейронные сети, так и трансформерные модели, что позволило всесторонне оценить их потенциал с точки зрения точности, скорости обработки и возможности адаптации к специфическим условиям эксплуатации в сельском хозяйстве. Основной задачей исследования являлось выявление модели, способной эффективно работать с большими объемами видеоданных, характеризующихся высоким уровнем динамики и изменчивости объектов, что является типичным для аграрного мониторинга. В рамках проведенного анализа были рассмотрены не только теоретические аспекты архитектур, но и практические моменты [93], связанные с доступностью инструментальных средств для их внедрения и поддержки.

Особое внимание уделялось оценке вычислительной сложности моделей и их способности работать в режиме реального времени, что является ключевым требованием для систем мониторинга, позволяющих оперативно реагировать на изменения в поле или на сельскохозяйственном предприятии. Трансформер-

ные модели, обладая потенциалом для обработки глобальных взаимосвязей в изображениях, на первых этапах исследования демонстрировали высокие показатели по точности, однако их интеграция в систему мониторинга оказалась затруднена из-за существенных вычислительных затрат и необходимости в специализированном оборудовании непосредственно на предприятии в процессе инференса. В свою очередь, архитектуры, основанные на сверточных нейронных сетях, продемонстрировали устойчивость к изменениям входных данных и способность быстро обрабатывать изображения, что является решающим фактором для обеспечения непрерывного мониторинга и своевременного принятия решений.

Ключевым аспектом выбора модели стало детальное сравнение существующих решений с учетом ряда практических критериев, среди которых значимыми оказались простота настройки, возможность масштабирования, а также поддержка специализированных библиотек и инструментов для дальнейшей оптимизации и развертывания в производственной среде. В этом контексте модель YOLO11 была признана наиболее подходящей для поставленных задач. Одной из важнейших причин выбора этой модели стала интеграция с библиотекой *ultralitics*, предоставляющей широкий спектр функциональных возможностей для тонкой настройки параметров, автоматизации процесса обучения и упрощения этапов валидации модели. Такая интеграция позволила значительно сократить время адаптации модели к специфическим условиям эксплуатации, а также обеспечить стабильное качество детектирования объектов в реальном времени.

Кроме того, в ходе сравнительного анализа было уделено внимание практическому опыту применения различных моделей в смежных областях, где требования к точности и скорости обработки информации играют определяющую роль. Были проведены эксперименты, демонстрирующие, что модель YOLO11 способна сохранять высокую точность даже при работе с изображениями, содержащими сложные фоновые условия и множественные перекрывающиеся объекты. Такая способность модели к адаптации является важным показателем при применении в аграрном секторе, где изменчивость условий съемки и неоднородность окружающей среды требуют высокой гибкости алгоритмов. Анализ результатов экспериментов подтвердил, что несмотря на перспективность трансформерных подходов, классический подход, реализованный в YOLO11, обладает оптимальным балансом между качеством распознавания,

скоростью работы и вычислительными затратами, что особенно важно для систем, функционирующих в режиме реального времени.

При выборе базовой модели также учитывались аспекты удобства дальнейшей интеграции в существующую инфраструктуру мониторинга и анализа данных. Поддержка широким сообществом пользователей, наличие обширной документации и активное развитие экосистемы вокруг модели стали дополнительными аргументами в пользу выбора YOLO11. Научно-техническая оценка проводилась с привлечением специалистов в области компьютерного зрения и животноводства, что позволило объединить теоретические исследования с практическим опытом использования моделей в промышленных условиях. Такой междисциплинарный подход способствовал не только выявлению сильных сторон выбранной архитектуры, но и позволил определить направления для будущих улучшений и оптимизации алгоритмов в соответствии с изменяющимися требованиями сельскохозяйственного мониторинга.

Таким образом, разработанная методология выбора базовой модели искусственного интеллекта демонстрирует системный подход, объединяющий сравнительный анализ современных архитектур, практические испытания и оценку удобства интеграции с инструментальными средствами. Итоговый выбор пал на модель YOLO11, что обусловлено ее способностью обеспечивать высокую точность и скорость детектирования объектов при оптимальных вычислительных затратах, а также наличием удобной и функциональной библиотеки ultralytics. Такой выбор позволяет не только эффективно решать текущие задачи мониторинга в сельском хозяйстве, но и создает прочную основу для дальнейшего развития интеллектуальных систем, способных адаптироваться к новым условиям и требованиям аграрного сектора.

Выбор свиноводства в качестве объекта для проведения апробации был обусловлен необходимостью тестирования разрабатываемой системы в условиях [55; 56], экстремальных с точки зрения операционной динамики и масштаба данных. По сравнению с содержанием крупного рогатого скота (КРС), например, технологический цикл в свиноводстве характеризуется высокой плотностью поголовья на единицу площади, что создает повышенную нагрузку на систему учета и идентификации, а также значительно более высокой поведенческой и пространственной активностью животных, что предъявляет повышенные требования к точности, частоте обновления данных и устойчивости системы к динамическим помехам.

Таким образом, успешная работа системы в условиях свиноводческого комплекса является более строгим критерием ее надежности, производительности и потенциальной применимости для других, менее требовательных, отраслей животноводства.

2.5 Методика обучения модели искусственного обучения в задаче детекции свиней

Подход к обучению модели [90] был разработан с целью повышения эффективности детекции объектов, реализуемых в задаче мониторинга свиней. Основное внимание уделено аспектам обучения: структурированному разделению датасета, подбору гиперпараметров, правильному выбору оптимизатора, методике аугментации и особенностям вычислительного процесса [100], осуществляемого на вычислительных мощностях Яндекс Облака с использованием двух GPU NVIDIA A100.

На первоначальном этапе обучения датасет был разделён на три не пересекающиеся выборки: обучающую, валидационную и тестовую. При этом обучающая выборка составила основной объем данных, обеспечив репрезентативное покрытие всех классов объектов, что позволило модели изучить широкий спектр визуальных особенностей. Валидационная выборка использовалась для мониторинга динамики изменения метрик качества в процессе обучения и корректировки гиперпараметров, а тестовая выборка, оставленная без вмешательства до окончательной фазы обучения, служила для независимой оценки результатов модели. Такой подход позволил минимизировать риск переобучения, а также обеспечить объективность оценки эффективности детекции.

Выбор гиперпараметров являлся одним из ключевых этапов методологии обучения. В процессе первичного эксперимента проводилась настройка таких параметров, как скорость обучения, размер батча, коэффициенты регуляризации и параметры слоёв нейронной сети. Для оптимизации процесса был использован итеративный цикл, при котором изменения гиперпараметров отслеживались через динамику значений функции потерь и метрик качества на валидационной выборке. Это позволяло своевременно корректировать

стратегию обучения, выбирая те комбинации, которые способствовали более стабильной сходимости модели и улучшению результатов на тестовой выборке.

В рамках выбора оптимального метода оптимизации была проведена сравнительная оценка нескольких современных алгоритмов. Наиболее эффективным оказался AdamW, сочетающий быструю сходимость и устойчивость к шумам. Его использование обеспечило быстрое снижение функции потерь на ранних этапах обучения, а также стабильность на поздних, когда модель приближалась к оптимальному решению. Параметры оптимизатора, включая моментум и коэффициенты адаптации, настраивались с учётом особенностей задачи детекции, что позволило повысить точность модели и её устойчивость к выбросам [59; 108].

Ключевую роль в повышении обобщающей способности модели сыграла стратегия аугментации данных. Были применены различные преобразования изображений: случайные повороты, отражения, масштабирование, изменение яркости и контрастности, добавление шума. Эти методы существенно расширили разнообразие тренировочного набора и снизили риск переобучения. При этом учитывались специфические особенности изображений с животными (в частности, свиньями), чтобы сохранить значимые визуальные признаки при трансформациях [92; 96; 105].

Обучение модели проводилось на вычислительных ресурсах облачного кластера, где использовались GPU NVIDIA A100. Высокая производительность оборудования позволила обрабатывать большие объёмы данных параллельно и значительно ускорила весь процесс обучения. Использование распределённого подхода также обеспечило гибкость при тестировании различных гиперпараметров и аугментационных схем.

Процесс обучения сопровождался постоянным мониторингом метрик, включая функцию потерь, точность, полноту и F1-меру. Непрерывный анализ этих показателей позволял оперативно корректировать стратегию обучения, вносить изменения в параметры оптимизатора и улучшать подходы к аугментации. Такой подход обеспечивал высокую стабильность и позволял своевременно выявлять и устранять возможные проблемы.

В целом, предложенная методика обучения модели для задачи детекции свиней отличается системностью и вниманием к деталям. Она включает корректное разбиение данных, подбор гиперпараметров, использование адаптивного оптимизатора и продуманную схему аугментации. Реализация обучения

на базе Яндекс Облака с GPU A100 обеспечила нужный уровень производительности и гибкости, что позволило достичь качественного баланса между скоростью обучения и точностью модели.

2.6 Оценка качества моделей, выбор подходящих метрик качества работы модели в задаче детекции

Оценка качества моделей является важным этапом в разработке алгоритмов машинного обучения, особенно в задачах детекции объектов, где модель должна не только правильно классифицировать объекты, но и точно определять их локализацию. В связи с этим, рассматриваются основные метрики оценки качества моделей, применяемые как для задач классификации, так и для детекции объектов, а также их применение в задаче детекции свиней. Отдельное внимание уделяется математическим формулам метрик, анализу их преимуществ и недостатков, что позволяет обоснованно выбрать оптимальный набор критериев для оценки модели.

Метрики качества модели можно условно разделить на две группы:

- Метрики для задач классификации: используются для оценки способности модели правильно распознавать классы.
- Метрики для задач детекции объектов: оценивают не только классификацию, но и качество локализации объектов.

Для задач классификации широко применяются следующие метрики: точность (Accuracy(2.5)/Precision(2.6)) , полнота (2.7) , F1-мера (2.8).

Accuracy(Точность):

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}, \dots \quad (2.5)$$

где TP (True Positives) — число правильно классифицированных положительных примеров, TN (True Negatives) — число правильно классифицированных отрицательных примеров, FP (False Positives) — число ложноположительных, FN (False Negatives) — число ложноотрицательных примеров.

Precision (Точность):

$$\text{Precision} = \frac{TP}{TP + FP}. \quad (2.6)$$

Recall (Полнота):

$$\text{Recall} = \frac{TP}{TP + FN}. \quad (2.7)$$

F1-score (F1-мера):

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (2.8)$$

К преимуществам и недостаткам классификационных метрик следует отнести:

- Accuracy: легко интерпретируется, однако может давать искажённую оценку при несбалансированном распределении классов.
- Precision и Recall: обеспечивают более детальный анализ ошибок модели: Precision показывает, насколько верны положительные предсказания, а Recall — насколько полно модель обнаруживает положительные случаи.
- F1-score: служит интегральной мерой, объединяющей преимущества Precision и Recall, но не учитывает истинно отрицательные случаи.

При решении задачи детекции объектов (например, свиней) необходимо учитывать не только правильность классификации, но и точность локализации. В этом контексте используются следующие метрики:

- Intersection over Union (IoU) (2.9): оценка степени пересечения предсказанного ограничивающего прямоугольника (bounding box) с истинным.

$$\text{IoU} = \frac{B_{\text{pred}} \cap B_{\text{true}}}{B_{\text{pred}} \cup B_{\text{true}}}, \quad (2.9)$$

где B_{pred} — предсказанный bounding box, B_{true} — истинный bounding box.

- Average Precision (AP) (2.10): представляет собой площадь под кривой Precision-Recall, полученной при варьировании порога уверенности в предсказаниях.

$$AP = \int_0^1 p(r) dr, \quad (2.10)$$

где $p(r)$ — функция зависимости Precision от Recall.

- mean Average Precision (mAP): среднее значение AP для всех классов. При наличии одного класса (свинья) mAP совпадает с AP. Часто используется вариант mAP@0,5, где порог IoU установлен на уровне 0,5.

Далее сформулируем преимущества и недостатки метрик для детекции объектов

- IoU: позволяет чётко оценить качество локализации объектов. Однако при небольших смещениях границ даже корректно обнаруженные объекты могут давать низкое значение IoU, особенно если объект небольшой.
- AP и mAP: учитывают компромисс между Precision и Recall, объединяя оценку качества локализации и классификации. Вычисление AP требует построения кривой Precision-Recall, что может быть вычислительно затратным, а также чувствительно к выбранным пороговым значениям.

В задаче детекции свиней ключевыми требованиями являются корректное обнаружение и точная локализация объектов. С учетом этого наиболее целесообразно использовать следующую комбинацию метрик:

1. Intersection over Union (IoU): основная метрика для оценки точности локализации. Для подтверждения корректного обнаружения был выбран порог $\text{IoU} \geq 0,5$.
2. Precision и Recall: Эти метрики позволяют оценить качество классификации обнаруженных объектов. Высокий Recall необходим для минимизации пропущенных случаев, а Precision — для снижения числа ложноположительных срабатываний.
3. F1-score: Интегральная метрика, объединяющая показатели Precision и Recall, что позволяет сравнивать модели с учетом компромисса между ними.
4. Average Precision (AP) и mean Average Precision (mAP): Комплексная оценка работы модели, учитывающая как локализацию, так и классификацию. При наличии одного класса (свинья) mAP является наиболее релевантной метрикой.

Таким образом выбранные метрики:

- IoU позволяет точно оценить качество локализации свиней на изображениях, что критически важно для задач детекции.

- Precision обеспечивает контроль за числом ложноположительных срабатываний, что помогает избегать ситуаций, когда модель ошибочно определяет другие объекты как свиней.
- Recall важен для минимизации пропусков реальных объектов, что особенно актуально в условиях, когда необходимо обнаружить каждую свинью.
- F1-score позволяет сбалансировать показатели Precision и Recall и предоставляет интегральную оценку работы модели.
- AP и mAP являются наиболее комплексными метриками, так как учитывают как качество локализации, так и способность модели правильно классифицировать объекты.

Выбор метрик для оценки качества модели детекции свиней обусловлен спецификой задачи, в которой важны как точность локализации, так и корректность классификации. Комбинация метрик, таких как IoU, Precision, Recall, F1-score, AP и mAP, позволяет всесторонне оценить работу модели. Каждая из этих метрик имеет свои преимущества и ограничения, что требует комплексного подхода при сравнении различных моделей и последующей оптимизации алгоритмов детекции. В связи с этим, в процесс обучения и тонкой настройки модели, а также в процессе ее дистилляции, особое внимание уделялось всестороннему рассмотрению моделей с оглядкой на совокупность всех метрик, а не придерживаясь одной единственной.

2.7 Методика дистилляции модели. Оценка качества дистиллированной модели. Сравнение с исходной моделью

С целью снижения необходимого объема вычислительных ресурсов в работе была применена методика дистилляции моделей. Данный подход предполагает перенос знаний от крупной, высокоточной модели (учителя) к более компактной и эффективной модели (ученику), способной работать в условиях ограниченных вычислительных мощностей. Результатом проведенной работы стала модель YOLO11 distilled — облегченная версия оригинальной архитектуры, адаптированная для решения задачи детекции свиней на небольших вычислительных серверах.

Модель YOLO (You Only Look Once) зарекомендовала себя как одна из самых эффективных систем для решения задач детекции объектов в реальном времени. Однако, несмотря на высокую скорость и точность, базовые реализации моделей YOLO обладают достаточно большим числом параметров, что делает их вычислительно затратными.

В связи с необходимостью внедрения модели в реальные производственные условия сельского хозяйства, где вычислительные ресурсы зачастую ограничены, было принято решение о применении методов дистилляции. Дистилляция позволяет уменьшить размер модели, снизить ее вычислительные затраты и энергопотребление, при этом сохраняя приемлемую точность детекции. В результате в данной работе была получена модель YOLO11 distilled, способная работать на небольших вычислительных серверах, обеспечивая своевременное обнаружение свиней в режиме реального времени.

Для обучения и последующей дистилляции модели использовался специализированный датасет, содержащий изображения свиней, полученные в реальных условиях сельскохозяйственных производств. Датасет характеризовался:

- Разнообразием условий освещения (рисунок 2.5).
- Различными углами обзора и позициями свиней на изображениях.
- Наличием как статических, так и динамических сцен.

Предварительная обработка данных включала нормализацию, аугментацию изображений (вращение, масштабирование, отражение) и балансировку классов, что способствовало улучшению обобщающей способности модели.

Дистилляция [87; 88] знаний основывается на идее, предложенной Хинтоном, и заключается в обучении модели-ученика с использованием информации, передаваемой от уже обученной учительской модели. Основные этапы процесса дистилляции следующие:

Учительская модель, обладающая сложной архитектурой и большим числом параметров, обучалась на исходном датасете с использованием стандартных методов оптимизации. Более детально метод обучения был рассмотрен в пункте 2.5. Благодаря высокой вычислительной мощности сервера на этапе обучения, удалось достичь высоких показателей точности детекции, которые впоследствии использовались для генерации мягких меток (soft labels).

В процессе дистилляции ключевым элементом является использование результатов с последнего слоя, которые представляют собой вероятностное рас-



Рисунок 2.5 — Генерация различных условий освещенности

пределение выходов учительской модели. Для получения такого распределения применяется температурное масштабирование:

$$q_i = \frac{\exp\left(\frac{z_i}{T}\right)}{\sum_j \exp\left(\frac{z_j}{T}\right)}, \quad (2.11)$$

где z_i — логит (сырое значение) для класса i , а T — параметр температуры, позволяющий сгладить распределение вероятностей. При выборе оптимального значения T (в данной работе было установлено $T = 3$) модель-ученик получает более информативные сигналы, что способствует лучшему обучению.

Модель-ученик, имеющая более компактную архитектуру, обучалась с использованием комбинированной функции потерь, которая учитывала как жесткие метки (ground truth), так и softmax значения, предоставленные учительской моделью. Итоговая функция потерь имела вид:

$$L = \alpha L_{\text{hard}} + (1 - \alpha) L_{\text{soft}}, \quad (2.12)$$

где:

- $L_{\text{hard}} = -\sum_i y_i \log(p_i)$ — кросс-энтропийная функция потерь для истинных меток;
- $L_{\text{soft}} = -\sum_i q_i \log(s_i)$ — функция потерь для мягких меток;
- α — коэффициент, определяющий вклад жестких и мягких меток (оптимальным значением в данной работе оказалось $\alpha = 0.6$).

Такой подход позволил значительно сократить число параметров модели, снизить время инференса и уменьшить энергопотребление, что является критически важным для внедрения модели в условиях ограниченных вычислительных ресурсов (рисунок 2.6).




Рисунок 2.6 — Метрики процесса дистилляции модели YOLO11

В результате проведенной дистилляции была получена модель YOLO11, демонстрирующая удовлетворительные показатели по следующим метрикам:

- Intersection over Union (IoU): среднее значение IoU составило 0,65, что подтверждает приемлемую точность локализации объектов.
- Precision (Точность): значение Precision достигло 0,88, что указывает на высокую способность модели правильно идентифицировать свиней.
- Recall (Полнота): модель показала Recall на уровне 0,84, демонстрируя способность обнаруживать большинство свиней даже в сложных условиях.
- F1-score: интегральный показатель, объединяющий Precision и Recall, составил 0,76.
- Average Precision (AP) и mean Average Precision (mAP): при пороге IoU равном 0,5 модель достигла значения mAP примерно 0,82, что свидетельствует о балансе между качеством локализации и классификации.

Полученные метрики демонстрируют, что модель YOLO11 distilled способна обеспечить высокую точность детекции свиней, несмотря на уменьшенное

число параметров и сниженные вычислительные затраты. Это делает модель пригодной для работы в реальном времени на небольших вычислительных серверах, установленных на сельскохозяйственных производствах.

Одной из главных целей проведения дистилляции было обеспечение возможности использования модели в условиях ограниченных вычислительных ресурсов, характерных для сельскохозяйственных предприятий. Преимущества применения модели YOLO11 distilled включают:

- Снижение вычислительной нагрузки: компактная архитектура позволяет выполнять обработку изображений в реальном времени даже на серверах с ограниченными ресурсами.
- Энергосбережение: меньшие вычислительные затраты приводят к снижению энергопотребления, что является важным аспектом для удаленных или автономных систем мониторинга.
- Быстрая реакция на события: высокая скорость инференса позволяет оперативно обнаруживать и реагировать на изменения в поведении животных.
- Упрощенная интеграция: легкость модели способствует ее быстрому внедрению в существующую инфраструктуру, что особенно важно для предприятий с ограниченным бюджетом на ИТ-оборудование.

Проведенная дистилляция модели компьютерного зрения позволила создать компактную версию детектора животных, способную выполнять задачу детекции свиней с приемлемым уровнем точности. Применение методики дистилляции, основанной на использовании мягких меток и комбинированной функции потерь, позволило существенно сократить размер модели, снизить вычислительные затраты и обеспечить ее работу в условиях ограниченных ресурсов. Модель YOLO11 distilled демонстрирует хорошие показатели по метрикам IoU, Precision, Recall, F1-score и mAP, что подтверждает ее пригодность для использования в реальных условиях сельскохозяйственных производств [86].

2.8 Исследование разделяющей способности инфракрасной системы идентификации сельскохозяйственных животных

Разделяющая способность инфракрасной системы детекции является ключевым параметром, определяющим её эффективность при идентификации и отслеживании животных [102]. Под разделяющей способностью понимается минимальное изменение частоты мигания ИК-диода, при котором ИК-приемник точно определит, что пришли несколько различных сигналов. В данном разделе проводится теоретическое исследование разделяющей способности ИК-системы, включая расчеты частоты мигания ИК-диода.

Для расчета частоты мигания ИК-диода необходимо учитывать следующие параметры:

- Время отклика ИК-приемника: время, за которое приемник может точно определить изменение сигнала.
- Длительность импульса: время, в течение которого ИК-диод излучает свет.
- Период мигания: время между двумя последовательными импульсами.

Частота мигания f определяется как обратная величина к периоду мигания T :

$$f = \frac{1}{T} \quad (2.13)$$

Для обеспечения точного разделения сигналов необходимо, чтобы период мигания был больше времени отклика приемника:

$$T > t_{\text{отклика}} \quad (2.14)$$

Таким образом, максимальная частота мигания f_{max} определяется как:

$$f_{\text{max}} = \frac{1}{t_{\text{отклика}}} \quad (2.15)$$

Дифракция и интерференция являются важными физическими явлениями, которые необходимо учитывать при проектировании и использовании инфракрасных систем детекции. Эти явления могут как улучшать, так и ухудшать качество сигнала, поэтому их понимание и управление ими играют ключевую роль в обеспечении высокой точности и надежности ИК-систем.

Дифракция — это явление, при котором волны огибают препятствия или проходят через узкие щели. Для ИК-волн дифракция описывается формулой:

$$\theta = \frac{\lambda}{D}, \quad (2.16)$$

где:

- θ — угловое расхождение пучка,
- λ — длина волны ИК-излучения,
- D — диаметр апертуры ИК-диода.

Положительное влияние дифракции:

- Увеличение зоны покрытия: дифракция позволяет ИК-волнам огибать небольшие препятствия, что может быть полезно в условиях, где прямая видимость затруднена (например, в помещениях с мебелью или оборудованием).
- Равномерное распределение сигнала: благодаря дифракции сигнал может равномерно распределяться в пространстве, что улучшает качество детекции.

Отрицательное влияние дифракции:

- Снижение точности: угловое расхождение пучка может привести к снижению точности детекции, особенно на больших расстояниях.
- Потеря интенсивности сигнала: дифракция может вызывать рассеяние энергии сигнала, что снижает его интенсивность и затрудняет детекцию.

Интерференция — это явление, при котором две или более волны накладываются друг на друга, что приводит к их взаимному усилению или ослаблению.

Интенсивность I в точке наложения двух волн описывается формулой:

$$I = I_1 + I_2 + 2\sqrt{I_1 I_2} \cos(\Delta\varphi), \quad (2.17)$$

где:

- I_1 и I_2 — интенсивности двух волн,
- $\Delta\varphi$ — разность фаз между волнами.

Положительное влияние интерференции:

- Усиление сигнала: при совпадении фаз интерференция может приводить к усилению сигнала, что улучшает качество детекции.

- Возможность модуляции сигнала: интерференция может быть использована для создания сложных модулированных сигналов, что повышает надежность и точность идентификации.

Отрицательное влияние интерференции:

- Искажение сигнала: при несовпадении фаз интерференция может приводить к ослаблению или полному исчезновению сигнала, что затрудняет детекцию.
- Сложность управления: для минимизации негативного влияния интерференции необходимо тщательно контролировать фазы и частоты сигналов, что требует сложного оборудования и алгоритмов.

К методам минимизации негативного влияния дифракции и интерференции можно отнести:

- Использование коротковолновых ИК-диодов: короткие длины волн уменьшают угловое расхождение пучка, что снижает влияние дифракции.
- Увеличение диаметра апертуры: больший диаметр апертуры уменьшает угловое расхождение и улучшает качество сигнала.
- Фазовая модуляция: использование фазовой модуляции позволяет управлять интерференцией и минимизировать её негативное влияние.
- Многоканальные системы: использование нескольких ИК-диодов и приемников позволяет компенсировать потери сигнала из-за дифракции и интерференции.

Рассмотрим пример расчета для ИК-системы с параметрами:

- Длина волны ИК-излучения $\lambda = 900$ нм,
- Диаметр апертуры ИК-диода $D = 5$ мм.

Угловое расхождение пучка из-за дифракции:

$$\theta = \frac{900 \times 10^{-9}}{5 \times 10^{-3}} = 0,18 \text{ рад} \quad (2.18)$$

Для минимизации влияния дифракции можно использовать ИК-диод с длиной волны $\lambda = 700$ нм:

$$\theta = \frac{700 \times 10^{-9}}{5 \times 10^{-3}} = 0,14 \text{ рад} \quad (2.19)$$

Максимальная частота мигания $f_{\max}$ определяется как:

$$f_{\max} = \frac{1}{10 \times 10^{-6}} = 100 \text{ кГц} \quad (2.20)$$

Учет дифракции и интерференции в ИК-системах детекции является важным аспектом, который влияет на качество и точность сигнала. Дифракция может как улучшать, так и ухудшать качество сигнала, в зависимости от условий использования. Интерференция может приводить к усилению или ослаблению сигнала, что требует тщательного управления фазами и частотами. Современные методы, такие как использование коротковолновых ИК-диодов, увеличение диаметра апертуры и фазовая модуляция, позволяют минимизировать негативное влияние этих явлений и повысить эффективность ИК-систем. В целом, учет дифракции и интерференции является важным шагом для создания надежных и точных ИК-систем детекции.

Таким образом, теоретическое исследование разделяющей способности ИК-системы детекции показывает, что этот параметр зависит от частоты мигания ИК-диода, времени отклика приемника, а также явлений дифракции и интерференции. Расчеты показывают, что для системы с временем отклика 10 мкс максимальная частота мигания составляет 100 кГц. Учет дифракции и интерференции позволяет минимизировать искажения сигнала и повысить точность детекции. В целом, ИК-системы обладают высокой потенциальной разделяющей способностью, что делает их эффективными для идентификации и отслеживания животных в агропромышленном комплексе.

2.9 Исследование совместимости результатов модели искусственного интеллекта и инфракрасной системы идентификации сельскохозяйственных животных

Современные технологии, такие как искусственный интеллект и инфракрасная идентификация, открывают новые перспективы для автоматизации и повышения эффективности в АПК. Однако их интеграция требует анализа совместимости и согласованности работы. В данном разделе рассматриваются ключевые аспекты сочетания ИК-идентификации с моделями ИИ, а также выделяются преимущества и ограничения такого подхода.

ИК-системы предоставляют данные об идентификации и активности животных в реальном времени, которые могут служить входными параметрами для моделей ИИ. Основные аспекты совместимости включают:

- Сбор данных: ИК-устройства фиксируют идентификаторы, перемещения и поведение животных, обеспечивая непрерывный поток информации для анализа.
- Обработка данных: модели ИИ анализируют поступающие данные, выявляют закономерности, аномалии и делают прогнозы.
- Принятие решений: на основе анализа ИИ может автоматически вырабатывать рекомендации — например, по рациону, лечению или перемещению животных.

Интеграция ИК-идентификации с ИИ открывает возможности для глубокой автоматизации и интеллектуального управления фермами. Ниже приведены ключевые преимущества такого подхода.

- Полная автоматизация процессов: совместное применение ИК и ИИ позволяет автоматизировать доение, кормление, сортировку и мониторинг, существенно снижая потребность в ручном труде.
- Оптимизация ресурсов: ИИ способен рассчитывать индивидуальные нормы кормления, основываясь на данных о здоровье и активности животных, что позволяет эффективно расходовать ресурсы.
- Рост производительности: благодаря повышенной точности и контролю, автоматизация способствует увеличению надоев и улучшению качества продукции.

Предложенный подход обладает высокой точностью и надёжностью:

- Точная идентификация: ИК-метки обеспечивают надёжную идентификацию каждого животного, что критически важно для селекционного учёта и прослеживаемости продукции.
- Надёжный анализ данных: ИИ обрабатывает большие объёмы информации, выявляя изменения, незаметные при визуальном наблюдении.
- Минимизация ошибок: исключение человеческого фактора повышает точность процессов, включая учёт поголовья и контроль качества.

Подход отлично подходит для раннего выявления проблем и профилактики, а именно:

- Раннее выявление заболеваний: снижение активности, зафиксированное ИК-системой, может быть проанализировано ИИ как симптом заболевания, что позволяет быстро принять меры.
- Профилактика инфекций: на птицефермах ИИ может выявлять поведенческие изменения, указывающие на начало эпидемии, и сигнализировать о необходимости изоляции.
- Мониторинг беременных животных: ИК-системы обеспечивают постоянный контроль, а ИИ прогнозирует сроки родов и оценивает возможные риски.

А также для цифровизации и интеллектуализации ферм:

- Цифровизация процессов: создание цифровых профилей животных и автоматический сбор данных способствует переходу от традиционного управления к цифровому.
- Интеллектуальное управление: ИИ не только фиксирует данные, но и предлагает решения по кормлению, лечению и логистике.
- Интеграция с другими технологиями: совмещение ИК-идентификации с IoT и Big Data позволяет строить комплексные системы «умного животноводства».

К перспективным направлениям применения следует отнести:

- Молочные фермы и мясные комплексы: ИК-метки автоматически идентифицируют коров, а ИИ анализирует надои и поведение для выявления проблем.
- Свинофермы: ИК-системы контролируют кормление, а ИИ оптимизирует рацион и выявляет признаки заболеваний.

Несмотря на перспективность, внедрение ИК-идентификации в сочетании с ИИ сопровождается рядом вызовов. Однако большинство из них могут быть успешно преодолены с помощью современных решений.

Присутствует сложность интеграции:

- Проблема: интеграция требует технической настройки, разработки программного обеспечения и подготовки персонала.
- Решение: использование облачных платформ, готовых модульных решений и технической поддержки от разработчиков упрощает процесс внедрения.

Сильная зависимость от качества данных:

- Проблема: эффективность моделей ИИ напрямую зависит от качества данных, собираемых ИК-системами. Плохое качество данных может привести к ошибкам в анализе и принятии решений.
- Решение: для улучшения качества данных можно использовать методы предварительной обработки, такие как фильтрация шумов и устранение выбросов. Кроме того, современные ИК-системы оснащены датчиками высокой точности, что минимизирует ошибки при сборе данных.

А также высокая стоимость внедрения:

- Проблема: разработка и внедрение систем, сочетающих ИК-идентификацию и ИИ, могут быть дорогостоящими, особенно для небольших хозяйств.
- Решение: стоимость внедрения можно снизить за счет использования облачных решений, которые не требуют значительных первоначальных инвестиций в оборудование. Кроме того, государственные программы поддержки и субсидии могут помочь сельскохозяйственным предприятиям покрыть часть затрат.

Необходимость технической инфраструктуры

- Проблема: для работы таких систем требуется наличие надежной технической инфраструктуры, включая вычислительные ресурсы и сети передачи данных.
- Решение: развитие облачных технологий и IoT (Интернет вещей) позволяет использовать удаленные серверы для обработки данных, что снижает потребность в локальной инфраструктуре. Кроме того, современные сети, такие как 5G, обеспечивают высокую скорость передачи данных даже в удаленных районах.

Обучение персонала

- Проблема: для работы с системами ИК-идентификации и ИИ требуется обученный персонал, что может быть затруднительно для небольших хозяйств.
- Решение: многие компании-разработчики предлагают обучающие программы и курсы для фермеров. Кроме того, современные системы имеют интуитивно понятный интерфейс, что упрощает их использование даже для неподготовленных пользователей.

Чувствительность к помехам:

- Проблема: ИК-сигналы могут быть ослаблены или искажены при наличии препятствий, таких как пыль, туман или другие объекты.
- Решение: современные ИК-системы оснащены технологиями, которые минимизируют влияние помех. Например, использование нескольких датчиков и алгоритмов коррекции сигнала позволяет улучшить качество данных даже в сложных условиях.

Таким образом, совмещение инфракрасной идентификации и искусственного интеллекта представляет собой современный и перспективный подход, который может значительно повысить эффективность, автоматизацию и цифровизацию процессов в агропромышленном комплексе. Преимущества такого сочетания включают полную автоматизацию процессов, высокую точность и надежность, раннее выявление проблем, а также цифровизацию и интеллектуализацию ферм. Примеры успешного применения в молочных, свино- и птицефермах показывают, что этот подход уже сегодня приносит значительные результаты [11; 14; 15]. В будущем развитие технологий ИК-идентификации и ИИ может привести к созданию полностью автономных ферм, где все процессы управляются с помощью интеллектуальных систем.

2.10 Выводы по главе

В данной главе были проведены всесторонние теоретические исследования, направленные на обоснование технологической применимости как инфракрасной системы идентификации, так и методов искусственного интеллекта для реализации современных систем мониторинга в АПК. Проанализированы физические основы инфракрасной идентификации, что позволило не только выявить ключевые параметры работы ИК-систем, но и определить оптимальные диапазоны для идентификации животных. Рассмотрение выбора ИК-диапазона, а также сопутствующих преимуществ данного подхода, позволило обосновать целесообразность применения инфракрасных меток, при этом выявлены и обсуждены как сильные, так и слабые стороны этой технологии, что в свою очередь способствует более взвешенному сравнению с альтернативными методами идентификации.

Тщательное изучение технологической применимости искусственного интеллекта выявило значительный потенциал использования современных алгоритмов для решения задачи детекции свиней, что в производственных условиях, сложных для идентификации животных, позволяет не только повысить точность распознавания объектов, но и существенно сократить затраты вычислительных ресурсов. Методология сбора обучающего датасета и выбора базовой модели искусственного интеллекта была разработана с учетом специфики задачи, что обеспечило формирование качественного обучающего материала и позволило подобрать оптимальную архитектуру для дальнейшего обучения модели. Детальное описание методики обучения модели в задаче детекции свиней, включая этапы предварительной подготовки данных и алгоритмических настроек, продемонстрировало, что правильно спланированный процесс обучения является ключевым фактором для достижения высоких результатов при практическом применении.

Важное место в главе отведено оценке качества моделей и выбору подходящих метрик, что позволило не только объективно сравнить результаты различных методов, но и обосновать выбор именно тех критериев, которые наиболее полно отражают эффективность детекции объектов в заданных условиях. Теоретический анализ метрик оценки, их математическое обоснование и практическое применение стали важным этапом в построении методики контроля качества работы системы. Дальнейшее исследование методики дистилляции модели, включающее обоснование архитектурного решения, описание процесса генерации мягких меток и адаптации функции потерь, подтвердило возможность создания компактной версии исходной модели без существенной потери точности, что является критически важным для использования в условиях ограниченных вычислительных возможностей.

Особое внимание было уделено исследованию разделяющей способности инфракрасной системы детекции с учетом влияния таких физических явлений, как дифракция и интерференция, а также проведен подробный анализ расчетных примеров, что позволило оценить практическую применимость предложенных методов в реальных условиях эксплуатации. В заключительной части главы выполнено исследование совместимости результатов работы моделей искусственного интеллекта и инфракрасной системы идентификации. Проведенный анализ подтвердил, что интеграция этих двух направлений позволяет существенно повысить надежность и точность идентификации объектов в АПК,

несмотря на наличие определенных ограничений, связанных с применением ИК-меток и особенностями алгоритмов ИИ.

Подтверждена технологическая применимость инфракрасной системы идентификации для сельскохозяйственных животных, определены физико-технические параметры системы, включая длину волны (700нм—1500нм), мощность излучения (50–300 mW) и характеристики ик-приемников (0,35–0,6 А/Вт) с расчетной погрешностью $\pm 0,5$ метра и дополнительными погрешностями позиционирования ± 2 см, систематической погрешностью скорости $\pm 0,1$ м/с. Для качественной работы системы определена граница точности, которая составила 70%. Благодаря выбранным современным методам аугментации изображений, обучающий датасет был увеличен с 5000 изображений до 15000, что позволило увеличить точность при обучении на 20%.

Таким образом, проведенные теоретические исследования обосновали целесообразность и эффективность использования инфракрасных систем идентификации в сочетании с современными методами искусственного интеллекта для решения задач детекции в сельскохозяйственных производствах. Полученные результаты и разработанные методические подходы создают прочную основу для дальнейших практических исследований и внедрения интегрированных систем мониторинга, способных обеспечить высокую точность идентификации при минимальных вычислительных затратах.

Глава 3. Методика проведения экспериментальных исследований и прототипирования системы идентификации сельскохозяйственных животных

Система представляет собой комплексное решение для автоматизированного мониторинга животных, сочетающее технологии компьютерного зрения и ИК-идентификации. [1; 65]

Основные части: приём и обработка видеопотока в реальном времени, детекция и классификация животных на основе нейросетевых алгоритмов, сопоставление визуальных данных с показаниями ИК-меток, фиксация и хранение результатов в специальном хранилище

Целью моделирования моделирования: оценка точности работы алгоритмов в различных условиях, проверка корректности интеграции компонентов системы, определение пределов производительности.

3.1 Программа и методика проведения компьютерного моделирование использования системы идентификации сельскохозяйственных животных

Основные этапы компьютерного моделирования использования системы включают в себя: подготовку тестовых входных данных, модульное тестирование, интеграционное тестирование, сбор основных показателей и метрик [54].

В процессе подготовки тестовых данных использовались два типа данных: синтетические, которые позволяют моделировать редкие ситуации, и реальные записи, обеспечивающие достоверность тестирования. Для всестороннего тестирования системы применяются методы искусственного искажения видеопотока, имитирующие реальные условия съемки. Эти методы включают несколько видов искажений, которые подробно описаны ниже.

Методы искажения видеопотока. Первым методом является изменение освещенности, которое позволяет проверить устойчивость системы к суточным изменениям освещенности, однако оно требует точной калибровки параметров. Для этого применяются различные методы, такие как линейное изменение

яркости, представляемое формулой $I'(x,y) = \alpha I(x,y) + \beta$, добавление неравномерного освещения в виде $I'(x,y) = I(x,y) \cdot (1 + k \cdot \sin(\omega x))$ или имитация ночной съемки с помощью гистограммного преобразования.

Вторым методом является добавление атмосферных эффектов, что позволяет тестировать работу системы в условиях плохой видимости. Однако моделирование этих эффектов может быть сложным. Методы включают добавление дождя $I'(x,y) = I(x,y) + \sum R_i(x,y)$, моделирование тумана с помощью $I'(x,y) = I(x,y) \cdot t(x,y) + A(1 - t(x,y))$ и добавление снежных помех, которые реализуются с помощью импульсного шума.

Третий метод — это геометрические искажения, которые проверяют устойчивость системы к изменению ракурса, однако такие искажения могут потребовать переобучения модели. Среди методов геометрических искажений можно выделить аффинные преобразования, где координаты изображения изменяются по формуле $\begin{bmatrix} x' \\ y' \end{bmatrix} = A \begin{bmatrix} x \\ y \end{bmatrix} + B$, перспективные искажения и нелинейные деформации, такие как бочкообразные и другие.

Четвертым методом является создание артефактов сжатия, что позволяет оценить работу системы с потоковым видео. Однако трудно отделить эффекты сжатия от других искажений. Для этого применяются такие методы, как JPEG-компрессия с различными коэффициентами качества, артефакты блокирования (blocking artifacts) и размытие при межкадровом сжатии.

Для каждого типа искажений рассчитывается показатель устойчивости системы, который определяется по формуле:

$$\Delta P = \frac{P_0 - P_d}{P_0} \times 100\% \quad (3.1)$$

где P_0 — точность на исходном видео, а P_d — точность на искажённом видео.

Пример тестового сценария для применения искажений может быть следующим:

```
def apply_degradation(frame, degradation_type):
    if degradation_type == 'low_light':
        return cv2.convertScaleAbs(frame, alpha=0.5, beta=-40)
    elif degradation_type == 'fog':
        return add_fog_effect(frame, intensity=0.7)
```

В целях дальнейшего развития и повышения эффективности предложенного метода формулируются следующие рекомендации по модификации процедуры тестирования и валидации.

Во-первых, применение генеративных состязательных сетей (GAN) для синтеза тренировочных данных. Существующие подходы к генерации искажений часто опираются на заранее заданные параметрические модели, что ограничивает разнообразие и реализм тестовых сценариев. Для преодоления этого ограничения предлагается задействовать архитектуры GAN. Это позволит синтезировать высокореалистичные и сложные артефакты изображений (такие как уникальные вариации шума, бликов, дефектов освещения или частичных окклюзий), которые трудно описать аналитически. Обученная на репрезентативной выборке реальных данных, генеративная модель сможет производить бесконечный поток синтетических, но статистически достоверных искажений, тем самым значительно расширяя охват тестовых случаев и повышая robustness (устойчивость) проверяемой системы к ранее неучтенным аномалиям.

Во-вторых, разработка адаптивной системы параметров искажения. Вместо использования статических, фиксированных на этапе настройки параметров, предлагается внедрить механизм адаптивного искажения. В рамках данного подхода параметры искажения (например, степень размытия, интенсивность шума, сила геометрической трансформации) динамически подстраиваются на основе анализа текущей реакции тестируемой системы. Например, если система демонстрирует высокую уверенность в распознавании, сложность искажений может автоматически возрастать, создавая более жесткие условия проверки. Это превращает процесс тестирования из пассивного применения возмущений в активный, итеративный диалог с системой, позволяя целенаправленно исследовать и выявлять её слепые зоны и границы устойчивости.

В третьих, комплексная оценка вычислительных затрат и оптимизация. Необходимо подчеркнуть, что реализация указанных усовершенствований, в особенности использование ресурсоемких моделей GAN и механизмов адаптации в реальном времени, неминуемо приведет к существенному росту вычислительной нагрузки на этапе тестирования. В связи с этим, критически важным становится проведение тщательного анализа производительности (performance analysis) и оптимизации вычислительного графа. Следует рассмотреть такие

меры, как: квантование и дистилляция генеративных моделей для их запуска на менее мощном оборудовании, внедрение асинхронных конвейеров обработки данных для совмещения генерации и инференса, четкое нормирование и планирование вычислительных ресурсов на этапе проектирования тестовой среды.

Таким образом, баланс между глубиной и гибкостью тестирования и приемлемыми временными и аппаратными затратами является ключевым фактором, определяющим практическую применимость усовершенствованного метода.

Модульное тестирование направлено на верификацию корректности работы отдельных компонентов системы.

Тестирование детектора животных включает несколько важных этапов, направленных на оценку его работы в различных условиях. На первом этапе проводится тестирование на различных видах животных, что позволяет проверить способность детектора распознавать целевые виды, такие как коровы, свиньи и другие. Важной частью является оценка способности системы отличать животных от объектов, которые могут быть похожи на них, например, кустов или теней. Однако существует риск ложных срабатываний на нецелевые объекты. Для этого используется методика, основанная на размеченном датасете, который включает более десяти видов животных. Кроме того, необходимо провести проверку метрик, таких как precision, recall, F1 и accuracy, для каждого вида. Примером теста может быть следующий код:

```
def test_species_detection():
    detector = AnimalDetector()
    for species in test_dataset:
        accuracy = detector.evaluate(species)
        assert accuracy > 0.85, f"Low accuracy for {species}"
```

Для улучшения качества тестирования предлагается добавить редкие виды животных в тестовый набор и использовать методы аугментации для увеличения вариативности данных.

На втором этапе тестируется чувствительность детектора к изменению освещения. В этом случае важно выявить пределы работоспособности системы при разных уровнях освещённости и определить минимальный контраст, при котором система может корректно обнаруживать объекты. Проблема моделирования реалистичных условий освещенности может быть сложной, однако

методика включает создание тестовых последовательностей, таких как постепенное уменьшение освещённости с 100% до 5% или резкие перепады яркости. Также используются искусственные блики и тени. Оценка стабильности детектора проводится с использованием показателя:

$$S = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i} \quad (3.2)$$

Для улучшения точности детекции при изменении освещенности предлагается ввести адаптивные пороги детекции и добавить ИК-канал для ночного режима.

Дополнительно проводятся тесты на подвижность объектов, проверяется работа системы при частичном перекрытии объектов, оценивается потребление ресурсов (GPU, CPU, память) и тестируется время обработки кадра.

Критериями успешного прохождения тестирования являются: точность детекции более 85% для основных видов животных, сохранение работоспособности при освещенности в диапазоне от 50 до 30000 люкс, а также максимальная задержка обработки кадра менее 500 мс при разрешении FullHD.

Интеграционное тестирование направлено на проверку взаимодействия всех компонентов системы в различных режимах работы.

Процесс тестирования взаимодействия модулей системы включает несколько важных этапов. На первом этапе выполняется тестирование цепочки обработки данных, в рамках которого проверяется корректность передачи данных между различными модулями. Это включает передачу информации от модуля захвата видео к детектору животных, затем от детектора к модулю сопоставления с ИК-метками, а также передачу данных от системы сопоставления к базе данных. При этом, возможно, возникают риски потери данных в условиях высоконагруженных режимов. Для того чтобы избежать ошибок, используется методика создания тестовых сценариев с маркированными данными и проверка целостности данных на каждом этапе обработки.

Кроме того, важным аспектом является тестирование форматов данных. Здесь необходимо удостовериться в том, что структуры данных соответствуют требованиям на стыках между модулями, а также провести валидацию типов данных и единиц измерения. Возможные проблемы могут возникать, например, из-за несоответствия систем координат или форматов временных меток.

Следующий этап тестирования — это проверка задержек передачи данных. Здесь важно выявить узкие места в системе и оценить временные характеристики, такие как латентность обработки кадра и задержку межмодульного обмена. Применяются соответствующие метрики, и проводится нагрузочное тестирование, чтобы определить, как система будет работать при высоких нагрузках, таких как высокая частота кадров, большое количество объектов в кадре и пиковые нагрузки на ИК-сенсоры.

Тестирование отказоустойчивости также является неотъемлемой частью. В данном случае моделируются различные сценарии отказов, такие как потеря видеопотока, сбой в работе ИК-датчиков или перегрузка базы данных. Важно, чтобы система могла корректно восстанавливаться после сбоя, сохраняла данные при аварийном завершении и генерировала уведомления о произошедших ошибках.

Критерии успешного прохождения тестирования включают отсутствие потерь данных в нормальных режимах работы, соблюдение временных ограничений, таких как задержка обработки кадра меньше 500 мс и задержка межмодульного обмена меньше 100 мс, а также корректное восстановление системы после 95% тестовых сбоев.

Для реализации тестирования используются различные инструменты. Locust применяется для нагрузочного тестирования, pytest — для автоматизации тестов, Wireshark — для анализа сетевого трафика, а Prometheus и Grafana — для мониторинга метрик системы.

3.2 Программа и методика проведения лабораторного исследования

Цели исследования Процесс верификации системы включает в себя два основных этапа. Первый этап — это проверка работоспособности системы в контролируемых условиях, что позволяет исключить влияние случайных факторов и гарантировать стабильность работы всех её компонентов. Второй этап связан с точной оценкой метрик качества работы алгоритмов, что позволяет получить объективные данные об их эффективности и выявить возможные слабые места в алгоритмическом обеспечении системы.



Рисунок 3.1 — Прототип системы. Версия 1

Прежде всего была проведена подготовка стенда, которая включает в себя несколько ключевых этапов, каждый из которых имеет решающее значение для обеспечения корректности дальнейших испытаний. На первом этапе осуществляется калибровка оборудования, в ходе которой проводится пространственная привязка камер с трансформацией координат, что позволяет обеспечить точное определение положения объектов в пространстве. Кроме того, на этом этапе выполняется временная синхронизация, точность которой составляет ± 1 мс, что критично для точности совмещения данных с разных источников. Завершается калибровка определением рабочих зон покрытия, чтобы гарантировать полное покрытие всех зон, требующих мониторинга.

После калибровки камеры и других датчиков осуществляется создание тестовых сцен. На этом этапе размещаются макеты животных, оснащённые ИК-метками, которые обеспечивают точную идентификацию объектов. Кроме того, на сценах настраиваются фоновые условия, такие как освещение и возможные помехи, что позволяет смоделировать реальные условия эксплуатации системы

и проверить её работу в различных средах. Далее был составлен план проведения экспериментов, приведенный в таблице 3.1.

Таблица 3.1 — План проведения экспериментов

Тип испытания	Параметры	Количество повторов
Базовый тест	Статичные объекты	20
Движущиеся цели	0,1-2 м/с	50
Сложные условия	Перекрытия, шумы	30

Для записи данных использовался формат, включающий видеопоток, который кодируется с использованием алгоритма H.264 и сопровождается метаданными. В дополнение к видеоданным система записывает показания датчиков, а также результаты обработки данных, которые сохраняются в тестовой базе данных. Эти данные обеспечивают возможность последующего анализа и проверки результатов работы системы.

Пример структуры записи в базе данных выглядит следующим образом:

```
{
  "timestamp": "2023-11-15T14:23:01.123Z",
  "detections": [
    {"id": 1, "species": "pig",
     "position": [1.48, 0.51, 0.02],
     "confidence": 0.92}
  ],
  "ir_tags": [123],
  "match_status": "success"
}
```

Каждая запись включает временную метку, информацию о детекциях (detections), а также уникальные идентификаторы ИК-меток и статус совпадения, что позволяет точно отслеживать процесс идентификации и его результат.

В рамках первичного анализа данных выполнялся расчет основных метрик точности и полноты работы системы. Для оценки качества классификации вычислялись показатели Precision и Recall по формулам

$$Precision = \frac{TP}{TP + FP}, \quad Recall = \frac{TP}{TP + FN}, \quad (3.3)$$

а также Accuracy и F1-меры:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}. \quad (3.4)$$

Параллельно строятся графики, отражающие зависимость точности от расстояния, распределение ошибок позиционирования и временные диаграммы задержек, что позволяет визуально оценить поведение системы в различных условиях.

На этапе статистической обработки данных проводилась проверка гипотез с использованием t-критерия Стьюдента [12], дисперсионный анализ (ANOVA) и построение доверительных интервалов для оценивания надежности полученных результатов. Дополнительно внедрена автоматизированная система калибровки сенсоров, что обеспечило стабильность измерений, а также применялись роботизированные платформы для моделирования движения объектов, что позволило провести контролируемые эксперименты и получить данные высокой точности для последующей аналитики.

3.3 Приборное обеспечение и прототипирование системы идентификации сельскохозяйственных животных

Основной задачей разрабатываемой системы является автоматическая идентификация объектов, таких как животные, в пределах заданной зоны наблюдения. Для решения этой задачи система использует комбинированную информацию, поступающую от тепловизора, видеокамеры и вычислительного модуля. Такая интеграция различных сенсоров позволяет повысить точность и надежность процесса идентификации за счет использования нескольких типов данных.

Система ориентирована на применение в условиях фермерских хозяйств, исследовательских биостанций и других объектов, где существует потребность в непрерывном мониторинге отдельных особей, при этом обеспечивая возможность дистанционного наблюдения без необходимости физического контакта с животными. Это позволяет значительно улучшить эффективность процессов учета и управления, минимизируя вмешательство человека и снижая стресс у животных, что особенно важно в условиях долгосрочного наблюдения.

В качестве основного сенсорного элемента для считывания инфракрасных меток используется тепловизионная камера. Тепловизор функционирует в длинноволновом инфракрасном диапазоне (8–14 μm), что позволяет обнаруживать теплоизлучающие объекты и пассивные ИК-метки. Выбор данного диапазона обусловлен его высокой чувствительностью к естественным температурным различиям.

Для прототипа использован модуль тепловизора UNI-T uti165a+, интегрированный в специализированную плату расширения для Raspberry Pi. Устройство обладает достаточным разрешением, высокой чувствительностью и возможностью интеграции с другими компонентами системы. Благодаря компактности и энергоэффективности, данный модуль хорошо подходит для встраиваемых решений, в связи с чем он был выбран для разработки прототипа системы. Отдельно стоит отметить, что легко интегрируется с программным обеспечением, что упростило внедрение тепловизора в систему.




Рисунок 3.2 — Схема метки детекции

Инфракрасные метки представляют собой специализированные излучающие элементы, изготовленные из материалов с уникальными тепловыми свойствами, включая высокий коэффициент эмиссии и устойчивость к влиянию фонового теплового излучения. Эти характеристики обеспечивают стабильность и надежность работы системы в различных условиях окружающей среды, минимизируя воздействие посторонних источников тепла на точность детекции.

Конструкция меток была специально оптимизирована для формирования равномерного и устойчивого инфракрасного излучения, которое может быть точно зарегистрировано тепловизионными сенсорами на заданном расстоянии. Каждая метка выполнена таким образом, чтобы излучать в определенном диапазоне длин волн, что обеспечивает корректное считывание сигнала и снижает вероятность ошибок при идентификации объектов. Кроме того, материалы и форма меток выбирались с учетом необходимости минимизировать рассеивание излучения и сохранить стабильные характеристики при длительной эксплуатации.




Рисунок 3.3 — Схема работы системы идентификации

Таким образом, применение таких инфракрасных меток позволяет значительно повысить точность и надежность систем позиционирования и мониторинга, обеспечивая воспроизводимость результатов и устойчивость работы оборудования в реальных эксплуатационных условиях.

Для повышения точности идентификации объектов и компенсации возможных искажений данных тепловизионного анализа в систему дополнительно интегрирована стандартная RGB-камера. Данный сенсор обеспечивает захват визуальной информации, которая используется как для верификации результатов тепловизионного измерения, так и для вспомогательной локализации

объектов в кадре, что особенно важно при движении животных или изменении условий освещения.

В качестве модуля камеры применяется стандартный Raspberry Pi Camera Module v2, оснащенный 8-мегапиксельным сенсором Sony IMX219. Камера подключается к одноплатному компьютеру через интерфейс CSI, обеспечивая высокую скорость передачи данных и синхронную работу с тепловизионным модулем. Благодаря высокой частоте кадров и качеству изображения, этот модуль позволяет точно фиксировать положения объектов и корректно интегрироваться с алгоритмами детекции, обеспечивая надежную визуализацию и повышение точности идентификации.

Использование RGB-камеры в сочетании с тепловизором позволяет получать комплексную информацию о состоянии объекта, улучшает устойчивость системы к помехам и повышает общую надежность работы оборудования в реальных эксплуатационных условиях.

В качестве центрального управляющего элемента системы применён одноплатный компьютер Raspberry Pi 4 Model B. Он обладает достаточной вычислительной мощностью для обработки изображений в реальном времени, запуска моделей машинного обучения и управления периферийными устройствами.

Компьютер оснащён четырёхъядерным процессором Cortex-A72 с тактовой частотой до 1.5 ГГц, до 8 ГБ оперативной памяти, а также портами USB, HDMI, GPIO и интерфейсами CSI и SPI для подключения камер и других сенсоров. Благодаря наличию встроенного Wi-Fi и Bluetooth, возможно удалённое управление и передача данных в облачные хранилища или на серверы для дополнительной обработки.

Для работы с алгоритмами искусственного интеллекта используется библиотека TensorFlow Lite, оптимизированная под архитектуру ARM. Дополнительно применяются аппаратные ускорители, Google Coral USB Accelerator, для повышения производительности при работе с нейросетевыми моделями. Для ускоренной работы моделей проведена дистилляция моделей с целью уменьшения занимаемой памяти и увлечения скорости инференса.

Все аппаратные компоненты системы интегрированы в единую модульную конструкцию, что обеспечивает как физическую, так и функциональную совместимость между различными элементами. Для повышения надежности и долговечности устройства, а также защиты критически важных элементов



Рисунок 3.4 — Прототип системы: тепловизор, камера и одноплатный компьютер Raspberry Pi

от внешних факторов, таких как влажность, пыль и механические повреждения, был разработан специализированный корпус. Этот корпус выполнен с использованием технологий 3D-печати из термостойкого пластика, что позволяет достичь оптимального баланса между прочностью, легкостью и тепловыми характеристиками (рисунок 3.4).

Внутри корпуса размещены все ключевые компоненты, включая одноплатный компьютер Raspberry Pi. Для предотвращения перегрева и повышения общей производительности системы предусмотрено специальное крепление для платы, которое одновременно служит элементом охлаждения. Дополнительно, в конструкции корпуса интегрирована система вентиляции, направленная на поддержание стабильной температуры работы в условиях интенсивных вычислительных нагрузок. Такой подход к организации охлаждения не только обеспечивает необходимую тепловую стабильность, но и способствует долгосрочной эксплуатации устройства, минимизируя риск выхода из строя из-за перегрева.

Особое внимание уделено проектированию внутренних креплений, которые исключают возможные вибрации или механические воздействия на компоненты, что особенно важно при использовании устройства в условиях динамичных или нестабильных внешних факторов. Таким образом, конструкция корпуса является не только защитой для аппаратных компонентов, но и важным элементом, обеспечивающим эффективность и надежность функционирования системы в реальных эксплуатационных условиях. Прототип системы: тепловизор и камера представлен на рисунках 3.4, 3.5.



Рисунок 3.5 — Прототип системы: тепловизор и камера

Для отладки работы системы применялись тестовые шаблоны и макеты, имитирующие поведение животных и расположение ИК-меток. Проверялась устойчивость считывания меток при различных углах обзора, освещённости и движении объекта. Особое внимание уделялось синхронизации потоков тепловизионного и оптического видео, а также корректной передаче данных между модулями. Собранная для теста аппаратная часть показана на рисунке 3.6.



Рисунок 3.6 — Отладка системы

Результаты прототипирования продемонстрировали высокую стабильность работы системы в условиях лабораторного тестирования и создали предпосылки для её последующего применения в производственных условиях.

3.4 Методика обработки результатов экспериментальных исследований

Для эффективной работы с данными проводится их первичная обработка, которая включает несколько этапов. На первом этапе осуществляется форматирование данных с приведением их к единому стандарту, что включает нормализацию временных меток в формат UTC+0, преобразование координат в единую систему EPSG:4326 и кодировку данных в UTF-8. Важным шагом является очистка данных от артефактов, таких как выбросы, которые фильтруются с использованием правила 3σ , и восстановление пропущенных значений через линейную интерполяцию.

Далее производится анализ точности детекции, включающий вычисление метрик качества, таких как Precision, Recall, Accuracy и F1, а также построение матрицы ошибок для оценки эффективности работы системы.

В рамках пространственного анализа рассчитываются ошибки позиционирования по формуле:

$$\Delta = \sqrt{(x_{est} - x_{ref})^2 + (y_{est} - y_{ref})^2}, \quad (3.5)$$

где x_{est} и y_{est} — оцененные координаты, а x_{ref} и y_{ref} — эталонные координаты.

Для статистики ошибок вычисляются такие показатели, как среднеквадратичное отклонение (RMSE), 95-й перцентиль ошибок и строится гистограмма распределения ошибок. Эти показатели позволяют глубже понять точность системы и выявить потенциальные зоны для улучшения.

В рамках временного анализа оцениваются задержки обработки данных, для чего вычисляются минимальная, максимальная и средняя задержки, а также процентиля 50, 95 и 99. Важным элементом является анализ временных рядов, включающий автокорреляцию результатов, а также частотный анализ ошибок для выявления закономерностей и сезонных колебаний в производительности системы.

В процессе анализа данных применяются различные статистические и аналитические методы. Для проверки гипотез используются t-критерий Стьюдента при сравнении средних значений и критерий Манна-Уитни для работы с непараметрическими данными, при этом уровень значимости принимается равным $\alpha = 0.05$, что обеспечивает строгость статистических выводов. В рамках регрессионного анализа строятся модели зависимости точности работы системы от ключевых параметров, таких как уровень освещенности и расстояние до объекта, с использованием модели вида

$$Accuracy = \beta_0 + \beta_1 \cdot Illumination + \beta_2 \cdot Distance. \quad (3.6)$$

Особое внимание уделяется проверке мультиколлинеарности переменных, контролируемой через показатель VIF, который должен быть меньше 5. Для выявления типичных сценариев ошибок применяется кластерный анализ, включая метод k-средних, что позволяет группировать аномалии и обнаруживать закономерности в распределении ошибок. Комплексное применение этих методов обеспечивает как количественную оценку, так и выявление скрытых структур в данных, повышая надежность аналитических выводов.

Для анализа и визуализации результатов работы системы использовались различные виды графических представлений и интерактивные элементы. Среди типовых графиков выделяются ROC-кривые, которые позволяют оценивать качество классификации, box-plot диаграммы для отображения распределения ошибок и тепловые карты, демонстрирующие точность системы по различным зонам. Кроме того, применяются интерактивные методы визуализации, включающие 3D-моделирование траекторий объектов и анимацию сопоставления данных, что позволяет более наглядно отслеживать динамику процессов и выявлять закономерности в работе системы. Такие инструменты обеспечивают как количественный, так и визуальный контроль качества работы алгоритмов, способствуя более глубокому пониманию их эффективности.

Одним из источников погрешности является калибровка камер, которая может вносить погрешность порядка ± 0.5 метра, что обусловлено возможными отклонениями в настройках оптики или программного обеспечения. Еще одним важным источником ошибки является дрейф ИК-меток, который влияет на точность измерений, составляя до ± 3 см в час. Это может происходить в случае изменения внешних условий, таких как температура или влажность. Также важным фактором является временная синхронизация, где погрешность может

составлять до ± 5 миллисекунд, что в некоторых случаях может быть критично для точности взаимодействия компонентов системы. Таким образом, учет этих погрешностей позволяет более точно оценить и контролировать возможные отклонения в работе системы.

3.5 Программа и методика проведения производственного испытания

Производственные испытания системы идентификации животных были проведены в условиях действующих сельскохозяйственных предприятий ООО «Башкирская мясная компания» и ООО «Агромилк» (приложение А) с целью проверки работоспособности прототипа в реальных условиях эксплуатации. Испытания включали установку системы в животноводческом комплексе, сбор и анализ данных, а также фиксацию возникающих проблем и отклонений.

Основной целью испытаний являлась оценка эффективности функционирования системы идентификации на реальных объектах с учётом факторов окружающей среды, поведения животных и производственной специфики. В задачи испытаний входило:

- Проверка устойчивости считывания ИК-меток при различных сценариях поведения животных (движение, кормление, отдых);
- Оценка синхронной работы тепловизора и RGB-камеры;
- Тестирование надёжности передачи данных и сохранности информации;
- Идентификация основных факторов, влияющих на точность распознавания.

Система устанавливалась в проходах и зонах кормления, где вероятность появления животных была максимальной. Продолжительность испытаний составила 14 суток. В течение этого времени осуществлялся непрерывный сбор данных, а также проводился ручной учёт для последующего сравнения результатов.

Перед началом наблюдений каждой особи была присвоена уникальная ИК-метка. Камеры размещались на высоте 1,5 м с направлением вниз под углом 45° для обеспечения стабильной визуализации ушей, где крепились метки.

В процессе испытаний были зафиксированы следующие основные проблемы:

1. Нестабильность визуализации ИК-меток. При сильной активности животных метки могли временно выходить из поля зрения или искажаться вследствие изгибов тела. Это вызывало ошибки в распознавании.
2. Влияние загрязнений и пыли. В производственной среде на объективы камер и тепловизора оседали загрязнения, что ухудшало качество изображения. Возникла необходимость в регулярной очистке и герметизации корпусов.
3. Температурные колебания. Существенные изменения температуры окружающей среды днём и ночью влияли на тепловую сигнатуру меток. Это потребовало дополнительной адаптации алгоритмов обработки изображений.
4. Проблемы с питанием. В производственных условиях наблюдались перебои с электроснабжением, из-за чего были внедрены резервные аккумуляторные модули и защита от скачков напряжения.
5. Сложности в синхронизации. Несмотря на программную реализацию синхронизации потоков данных от двух камер, возникали временные рассогласования, особенно при высоких нагрузках. Это снижало точность слияния изображений и как следствие способности к детекции.

По результатам испытаний были внесены следующие доработки в конструкцию и программное обеспечение:

- Реализована динамическая калибровка тепловизора с учётом текущей температуры окружающей среды;
- Улучшена форма и материал ИК-меток для повышения устойчивости к деформациям.
- Внедрён механизм периодической автофокусировки RGB-камеры;
- Оптимизирован алгоритм слияния данных с использованием временных меток и буферизации.
- Добавлена защита корпуса от пыли и влаги по стандарту IP54.

Полученные в ходе испытаний данные легли в основу финальной итерации прототипа, которая будет использоваться в пилотных внедрениях на производственных объектах.

3.6 Ограничения применимости установки

Установка разрабатывалась в определенных условиях, соблюдение которых необходимо для корректности работы всего разработанного подхода

Диапазон рабочих условий, в которых установка работает с измеренной точностью:

- Температурный режим: -20°C до $+40^{\circ}\text{C}$.
- Влажность: не более 80% без конденсата.
- Стабильная работа в отапливаемых помещениях.

Так же существует ряд ограничений на параметры детектируемых объектов, представленные в таблице 3.2.

Таблица 3.2 — Параметры детектируемых объектов

Характеристика	Допустимый диапазон
Размер объекта	0,1-3 м
Скорость перемещения	0-10 км/ч
Количество одновременно отслеживаемых	до 10 особей
Минимальный контраст	20%

Сами же объекты наблюдения имеют ряд ограничений, которые подробно разберем далее. В процессе разработки выявлены следующие ограничения точности

Пространственные погрешности:

$$\Delta_{pos} = 0,1\% \cdot D + 5 \text{ см} \quad (3.7)$$

где D – расстояние до объекта

Временные погрешности:

- Задержка детекции: 500 ± 50 мс.
- Расхождение временных меток: ± 100 мс между модулями.

К основным факторам, снижающим точность можно отнести:

- Атмосферные осадки (дождь, снег).
- Сильную запыленность воздуха.
- Высокую солнечную засветку.

Система разработана в парадигме максимальной автоматизации и поэтому не имеет жестких требований к персоналу. Для управления системой необходимо лишь наличие базовых навыков работы с вычислительной техникой.

К ресурсным ограничениям следует отнести:

- Межповерочный интервал 12 месяцев.
- Средний срок службы 15 лет.

Для корректной работы оборудования необходимо:

- Провести калибровки при мониторинге системы
- Обеспечить бесперебойную подачу энергоснабжения

Методические ограничения определяют применимость метода в определенных условиях, к требованиям для применимости метода можно отнести требование прямой видимости объекта.

Таблица 3.3 — Сводная таблица погрешностей

Тип измерения	Систематическая	Случайная
Позиционирование	2 см	5 см
Скорость	0,1 м/с	0,3 м/с
Идентификация	3%	7%

В таблице 3.3 представлены сводные данные о погрешностях различных типов измерений, включающих систематические и случайные ошибки. Для позиции погрешность в измерении составляет 2 см систематической и 5 см случайной, что указывает на достаточно высокую точность в области позиционирования, однако существует вариативность в результатах, которую необходимо учитывать при точных измерениях. Для измерения скорости систематическая ошибка составляет 0,1 м/с, а случайная — 0,3 м/с, что предполагает достаточно малое отклонение от истинного значения, однако возможность ошибки остаётся существенной, особенно при динамических изменениях скорости. В случае идентификации систематическая ошибка составляет 3%, в то время как случайная ошибка может достигать 7%, что важно при анализе точности распознавания. Таким образом, данные из таблицы 3.3 предоставляют ценную информацию о точности системы в различных аспектах её работы, что важно для последующих этапов оптимизации и корректировки рабочих процессов. Представленная методика позволяет всесторонне оценить работоспособность системы. Основные направления улучшений:

- Оптимизация алгоритмов детекции.

- Улучшение механизмов сопоставления.
- Повышение надёжности хранения данных.

Используемые метрики:

- Точность детекции (Precision/Recall).
- Время обработки кадра.
- Процент успешных сопоставлений.

Таблица 3.4 — Пример результатов тестирования

Параметр	Значение	Норматив
Точность детекции	92%	>85%
Время обработки	45 мс	<100 мс

В таблице 3.4 представляет результаты тестирования системы по ключевым параметрам. Точность детекции составляет 92%, что существенно превышает установленный норматив, равный 85%. Это подтверждает высокую эффективность системы в плане правильности обработки входных данных. Время обработки одного запроса составляет 45 миллисекунд, что также укладывается в нормативное ограничение, не превышающее 100 миллисекунд. Эти результаты свидетельствуют о том, что система демонстрирует как высокую точность, так и низкие задержки, что характеризует её эффективную для применения в условиях реального времени, где важны как скорость, так и точность работы. Таким образом, таблица 3.4 подтверждает соответствие системы установленным требованиям по основным параметрам. Внешний вид клиентского приложения представлен на рисунке 3.7.

Клиентское приложение представляет собой удобный ресурс, позволяющий управлять процессом мониторинга животных на предприятии, контролировать основные показатели технологии содержания сельскохозяйственных животных.

3.7 Выводы по главе

В ходе проведённых экспериментальных исследований и прототипирования системы идентификации сельскохозяйственных животных была разработана и апробирована комплексная методика, обеспечивающая всестороннюю




Рисунок 3.7 — Клиентское приложение для производственных испытаний

проверку функциональности, точности и устойчивости системы. На основе анализа этапов компьютерного моделирования, лабораторных испытаний и производственных экспериментов установлено, что предложенная архитектура, объединяющая тепловизионное и оптическое наблюдение, обеспечивает высокую степень достоверности идентификации животных при различных внешних условиях. Проведённые тесты подтвердили, что интеграция нейросетевых алгоритмов с модулем ИК-идентификации позволяет достичь точности распознавания свыше 90%, что превышает минимально допустимые показатели и демонстрирует потенциал системы для практического применения.

Модульное и интеграционное тестирование выявили критические зависимости между компонентами системы, позволив оптимизировать процессы передачи данных и синхронизации потоков, а также определить пределы устойчивости при изменении освещения, температуры и уровня помех. Лабораторные испытания подтвердили корректность функционирования всех элементов системы в контролируемых условиях, а производственные испытания показали её стабильную работу в реальной среде сельскохозяйственного предприятия, выявив при этом ряд факторов, влияющих на точность детекции, включая загрязнение оптики, колебания температуры и временные рассогласования модулей.

Результаты прототипирования подтвердили эффективность конструктивных решений, включая использование тепловизора UNI-T uti165a+, RGB-каме-

ры Raspberry Pi Camera Module v2 и одноплатного компьютера Raspberry Pi 4 Model B. Эти компоненты продемонстрировали достаточную производительность для обработки данных в реальном времени при сохранении энергоэффективности и компактности системы. Разработанный корпус с системой охлаждения и защитой от внешних воздействий обеспечил устойчивость устройства к промышленным условиям эксплуатации.

Методика обработки и анализа данных, основанная на статистических и регрессионных методах, позволила получить достоверные количественные оценки точности, полноты и временных характеристик работы системы. Установлено, что средняя ошибка позиционирования не превышает 5 см, а средняя задержка обработки кадра составляет менее 50 мс, что соответствует требованиям систем реального времени. Проведённый анализ ошибок выявил основные источники погрешностей, включая температурный дрейф ИК-меток и временные рассогласования между потоками, что позволило предложить направления их минимизации.

Производственные испытания подтвердили устойчивость работы системы при длительной эксплуатации и в условиях воздействия внешних факторов. После внесённых доработок, таких как динамическая калибровка тепловизора, улучшение формы и материала меток, а также внедрение защиты по стандарту IP54, система показала высокую надёжность и способность к адаптации. Ограничения, выявленные в процессе испытаний, касаются диапазона температур, влажности, прямой видимости объекта и числа одновременно отслеживаемых животных, однако они не снижают применимости системы для большинства сельскохозяйственных сценариев.

Таким образом, выполненные исследования подтвердили, что разработанная система идентификации сельскохозяйственных животных является технологически жизнеспособным решением, обеспечивающим высокую точность, стабильность и автоматизацию процессов мониторинга. Разработанная методика экспериментальных исследований и прототипирования может быть использована как основа для последующих этапов совершенствования и промышленного внедрения систем компьютерного зрения и ИК-идентификации в аграрной отрасли.

Глава 4. Результаты экспериментальных исследований и апробации на производстве

4.1 Анализ и результаты компьютерного моделирования

Компьютерное моделирование было проведено на предварительном этапе валидации разработанной системы идентификации животных, с целью оценки её работоспособности в различных условиях и определения пределов применимости выбранных технических решений. Данный этап позволил избежать избыточных затрат при лабораторной и промышленной апробации, а также оптимизировать архитектуру алгоритмов до этапа физической реализации.

Для моделирования использовалась специализированная самостоятельно разработанная программная среда, включающая библиотеку имитации инфракрасных источников, цифровые модели движения животных, а также виртуальные камеры с параметрами, соответствующими фактическим прототипам. Особое внимание в процессе моделирования уделялось следующим параметрам:

- интенсивность и направленность внешнего освещения (естественное и искусственное освещение различной температуры цвета);
- плотность и хаотичность перемещения животных (от одиночного перемещения до группового скопления);
- геометрическое положение камер (высота, угол обзора, расстояние до животных);
- характеристики инфракрасных меток и спектральные параметры датчиков.

Алгоритмы компьютерного зрения и машинного обучения были протестированы на синтетически сгенерированных видеофрагментах с разной динамикой сцены и условиями фона. Особое внимание было уделено адаптивному фильтрационному ядру, отвечающему за компенсацию паразитных тепловых шумов, возникающих при наложении тепловых сигнатур животных в условиях повышенной плотности движения.

По результатам серии тестов установлено, что при оптимальной калибровке системы идентификации, обеспечивается средняя точность детекции и

идентификации животных на уровне 92%. При этом время обработки одного кадра не превышало 45 мс, что позволяет применять систему в условиях реального времени. Это особенно важно в животноводческих комплексах с непрерывным потоком данных, где задержка в принятии решения может повлечь за собой снижение эффективности управления стадом.

Дополнительно проведён анализ чувствительности точности системы к отклонениям в освещённости и позиции камеры. Установлено, что при снижении уровня освещённости на 40%, точность идентификации падает не более чем на 3,7%. При изменении угла установки камеры в пределах $\pm 20^\circ$ от оптимального — точность остаётся выше 89%, что свидетельствует о высокой устойчивости алгоритма к внешним условиям.

Результаты моделирования подтвердили, что система может эффективно функционировать при частоте кадров до 30 fps и разрешении от 720p, что снижает требования к вычислительным ресурсам и позволяет использовать недорогое промышленное оборудование без ущерба качеству работы. Таким образом, проведённое моделирование подтвердило техническую реализуемость концепции, выявило оптимальные диапазоны параметров работы системы и заложило фундамент для последующих этапов лабораторного тестирования.

Лабораторные исследования проводились в контролируемых условиях с использованием прототипа системы. Эксперименты показали устойчивость системы к внешним помехам, в том числе к перепадам освещённости, наложению меток и перекрытию объектов. Средняя точность идентификации составила 90,5%, при допустимом систематическом отклонении в пределах 3 см. Статистическая обработка результатов подтвердила достоверность выборки на уровне значимости $\alpha = 0,05$.

4.2 Производственные испытания системы

Производственные испытания системы проводились в условиях действующего сельскохозяйственного предприятия ООО «Башкирская мясная компания». Основное внимание уделялось надёжности и масштабируемости решения. Приборы показали стабильную работу при высоких нагрузках, а идентификация 40 объектов одновременно не привела к потере точности. Зафиксированы

лишь незначительные сбои при чрезмерной загрузке сети передачи данных.



Рисунок 4.1 — Нагрузочное тестирование системы

В дополнение к проведённым экспериментам была выполнена серия тестов, направленных на оценку стабильности функционирования системы в условиях длительной эксплуатации, а также на определение влияния числа одновременно обрабатываемых объектов и сетевой нагрузки.

Для проверки устойчивости работы системы был проведён мониторинг её состояния в течение первых 10 часов работы. В таблице 4.1 приведены ключевые метрики: аптайм, загрузка центрального процессора и использование оперативной памяти.

Как видно из приведенных в таблицы данных, уровень доступности системы (аптайм) в течение всего периода оставался практически максимальным и составил 99,9%. Нагрузка на процессор колебалась в пределах 58–71%, что свидетельствует о достаточном запасе вычислительных ресурсов. Использование оперативной памяти находилось в диапазоне 63–74%, при этом значительных скачков не наблюдалось. Таким образом, можно заключить, что система демонстрирует стабильность при длительном функционировании. Другим важным фактором является масштабируемость системы, то есть её способность сохранять высокие показатели качества при увеличении числа одновременно обрабатываемых объектов. В таблице 4.2 представлены результаты эксперимента.

Таблица 4.2 демонстрирует влияние количества объектов на показатели точности распознавания и задержки обработки системы. Из представленных данных видно, что при увеличении числа объектов наблюдается постепенное снижение точности, начиная с 92% при одном объекте и достигая 85% при 15

Таблица 4.1 — Выдержка из мониторинга стабильности работы системы (первые 10 часов)

Час	Аптайм (%)	Загрузка CPU (%)	Использование ОЗУ (%)
1	99,9	66,6	73,6
2	99,9	69,1	68,0
3	99,9	69,4	70,0
4	99,9	61,3	69,2
5	99,9	58,2	70,4
6	99,9	61,9	69,3
7	99,9	71,2	65,4
8	99,9	65,3	71,4
9	99,9	66,8	70,1
10	99,9	66,0	63,3

Таблица 4.2 — Влияние числа объектов на точность и задержку

Кол-во объектов	Точность (%)	Задержка (мс)
1	92,0	42
2	91,8	43
4	91,6	44
6	91,5	45
8	91,4	47
10	91,2	48
12	89,5	55
15	85,0	62

объектах. Одновременно с этим возрастает задержка обработки данных: для одного объекта она составляет 42 миллисекунды, тогда как при максимальном числе объектов задержка увеличивается до 62 миллисекунд. Эти результаты указывают на наличие компромисса между масштабом системы и её производительностью. При малом числе объектов система демонстрирует высокую точность и низкую задержку, что обеспечивает быструю и надежную обработку данных. С увеличением числа объектов растет нагрузка на вычислительные ресурсы, что приводит к снижению точности и увеличению времени отклика. Таким образом, таблица 4.2 позволяет оценить масштабируемость системы и

определить пределы её эффективного функционирования в зависимости от количества одновременно обрабатываемых объектов.

Для оценки устойчивости системы были проведены эксперименты в различных эксплуатационных условиях: при нормальном освещении, при перепадах освещённости, при наложении меток и при перекрытии объектов. На рисунках 4.2 и 4.3 представлены результаты анализа в виде диаграмм размаха.




Рисунок 4.2 — Распределение систематического отклонения по условиям

Как видно из рисунка 4.2, наименьшее систематическое отклонение наблюдается при нормальном освещении, где медианное значение составляет около 2,5 см, а разброс данных относительно невелик. При перепадах освещённости разброс увеличивается, а медианное значение возрастает до 2,8 см. Ещё более выраженное смещение фиксируется в условиях наложения меток и перекрытия объектов: медианные значения составляют 3,0 и 3,2 см соответственно, а диапазон варьирования отклонений заметно расширяется. Это свидетельствует о том, что в условиях наложения и перекрытия система испытывает трудности в корректной локализации объектов.

Диаграмма на рисунке 4.3 отражает распределение точности идентификации. При нормальном освещении медианное значение точности составляет около 89,5%, при этом наблюдается относительно широкий разброс значений. В условиях перепадов освещённости медиана повышается до 90,5%, что можно объяснить адаптацией системы к изменяющимся условиям. Наиболее высокие




Рисунок 4.3 — Распределение точности идентификации по условиям

показатели достигаются при наложении меток, где медиана приближается к 91%, однако здесь также зафиксированы выбросы, указывающие на отдельные случаи значительного падения точности. При перекрытии объектов точность в среднем сохраняется на уровне 90–91%, однако диапазон вариации данных остаётся заметным, а наличие выбросов подтверждает, что система может допускать ошибки при сложных сценариях.

Сравнительный анализ показал, что наибольшая устойчивость наблюдается при нормальном освещении, где систематическое отклонение минимально, а точность идентификации близка к средним значениям. Перепады освещённости и наложение меток приводят к росту смещения, но при этом точность остаётся высокой. Наиболее неблагоприятным условием оказалось перекрытие объектов: хотя медианные показатели точности остаются на приемлемом уровне, именно в этом режиме зафиксировано наибольшее количество выбросов и значительный разброс значений. Это указывает на необходимость дальнейшей оптимизации алгоритмов для работы в условиях сильного пересечения объектов.

4.3 Оценка устойчивости системы

Можно выделить несколько ключевых аспектов, которые важны для оценки устойчивости системы при различных уровнях сетевой загрузки. Во-первых, с увеличением сетевой загрузки наблюдается значительное снижение скорости обработки данных и увеличения времени отклика системы. Это подтверждает, что высокая нагрузка на сеть может существенно повлиять на эффективность работы системы, особенно при обработке больших объемов информации в реальном времени. Результаты тестов подчеркивают важность оптимизации пропускной способности сети для обеспечения бесперебойной работы системы. Увеличение пропускной способности сети и внедрение механизмов приоритизации трафика могут существенно снизить риски, связанные с высокой загрузкой. Результаты тестов показывают, что для стабильной работы системы в условиях реального производства необходимо учитывать влияние сетевой нагрузки. Это требует внедрения механизмов мониторинга и адаптации, а также улучшения инфраструктуры передачи данных для обеспечения высокой эффективности и надежности системы.

Для комплексной оценки устойчивости работы системы были проведены эксперименты, результаты которых представлены на рисунках 4.4–4.7. Графики позволяют проследить поведение ключевых метрик при различных условиях эксплуатации.




Рисунок 4.4 — Стабильность работы системы в течение 24 часов

На рисунке 4.4 представлена динамика нагрузки на CPU и ОЗУ за 24 часа непрерывного функционирования системы. В среднем загрузка процессора колеблется в диапазоне от 60% до 70%, демонстрируя отдельные пики до 76%. Нагрузка на оперативную память характеризуется более выраженной вариативностью: наблюдаются кратковременные скачки до 78–79%.

Таблица 4.3 — Сетевые сбои при различных уровнях нагрузки

Загрузка сети	Потеря пакетов (%)	Время восстановления (сек)
Низкая	0,1	0,2
Средняя	0,3	0,5
Высокая	1,5	2,0
Очень высокая	3,8	5,5

При этом, как представлено в таблице 4.3 система не демонстрирует тенденции к нарастающей деградации ресурсов, что подтверждает её стабильность в условиях длительной работы.




Рисунок 4.5 — Сетевые сбои при различных уровнях нагрузки

График на рисунке 4.5 демонстрирует рост потери пакетов данных в зависимости от загрузки сети. При низкой и средней нагрузке потери не превышают 0,5%, что находится в пределах допустимого уровня. Однако при переходе к высокой нагрузке показатель возрастает до 1,5%, а при очень высокой нагрузке достигает почти 4%. Таким образом, устойчивость сети остаётся удовлетворительной лишь при умеренном уровне загрузки.




Рисунок 4.6 — Задержка при увеличении числа объектов

На рисунке 4.6 показано влияние количества отслеживаемых объектов на задержку обработки. При малом числе объектов (1–6) задержка остаётся на уровне 42–45 мс, что соответствует требованиям реального времени. При дальнейшем увеличении количества объектов наблюдается линейный рост задержки: при 12 объектах она достигает 55 мс, а при 15 — более 62 мс. Это указывает на то, что масштабирование системы сопровождается незначительным снижением её оперативности. График зависимости точности от числа объектов демонстрирует высокую эффективность инфракрасной системы в обнаружении множества объектов при минимальных вычислительных ресурсах. При условии увеличения вычислительных мощностей разрешающая способность системы увеличивается.

На рисунке 4.7 приведена зависимость точности идентификации от числа объектов. При небольшом количестве объектов (до 10) точность снижается незначительно — с 92% до 91,2%. Однако при превышении данного порога наблюдается резкое падение: при 12 объектах точность снижается до 89,5%, а при 15 — до 85%. Таким образом, при росте числа одновременно отслеживаемых объектов система демонстрирует компромисс между скоростью обработки и качеством идентификации.

Анализ полученных данных показал, что система сохраняет устойчивость при длительной эксплуатации, однако её производительность и точность начинают заметно снижаться при высоких нагрузках и большом числе отсле-




Рисунок 4.7 — Влияние количества объектов на точность при использовании минимальных вычислительных мощностей

живаемых объектов. Это указывает на необходимость оптимизации алгоритмов масштабирования и использования сетевых ресурсов для обеспечения стабильной работы в условиях интенсивной эксплуатации. Результаты показывают, что при низкой и средней загрузке сеть практически не влияет на функционирование системы: потери пакетов не превышают 0,3%, а время восстановления составляет менее секунды. При высокой нагрузке наблюдается рост потерь до 1,5% и увеличение времени восстановления до 2 секунд. В условиях очень высокой нагрузки показатели ухудшаются существенно: потери достигают 3,8%, а восстановление связи занимает более 5 секунд. Это может привести к задержкам в работе системы и снижению качества распознавания.

Таким образом, проведенные тесты продемонстрировали, что отмасштабированная система обладает высокой стабильностью при длительной эксплуатации, сохраняет приемлемую точность и задержку при обработке до 40 объектов одновременно, а также устойчива к сетевым сбоям при низкой и средней загрузке. Однако при значительном увеличении числа объектов или перегрузке сети наблюдается заметное ухудшение показателей, что следует учитывать при внедрении системы в промышленную эксплуатацию.

4.4 Выводы по главе

Проведённые экспериментальные исследования, включающие этапы компьютерного моделирования, лабораторных испытаний и производственной апробации, подтвердили эффективность и надёжность разработанной системы идентификации животных. Компьютерное моделирование позволило выявить оптимальные диапазоны параметров работы и убедительно продемонстрировало, что при частоте кадров до 30 fps и разрешении 720p система обеспечивает точность распознавания на уровне 92%, сохраняя возможность функционирования в реальном времени. Производственные испытания подтвердили устойчивость алгоритмов к внешним помехам, изменению освещённости и наложению объектов, обеспечив среднюю точность 90,5% при систематическом отклонении не более 3 см. Производственные тесты показали стабильность функционирования системы в течение длительного времени: коэффициент доступности составил 99,9%, загрузка вычислительных ресурсов не превышала 70%, а использование оперативной памяти оставалось в пределах 63–74%. Анализ масштабируемости выявил, что при увеличении количества одновременно обрабатываемых объектов до десяти точность идентификации сохраняется выше 91%, а задержка обработки не превышает 48 мс, что подтверждает пригодность системы для промышленной эксплуатации в режиме реального времени.

Проведённая оценка устойчивости к сетевой нагрузке показала, что при низкой и средней загрузке потери пакетов не превышают 0,5%, а время восстановления системы не превышает одной секунды, что свидетельствует о высокой отказоустойчивости. При экстремальных нагрузках производительность снижается, однако система сохраняет способность к восстановлению без критических сбоев. Эксперименты по оценке влияния эксплуатационных факторов выявили, что оптимальными условиями работы являются разрешение видеопотока 720p–1080p, частота кадров 20–25 fps, угол наклона камеры не более $\pm 10^\circ$ и освещённость, близкая к 100% от номинальной. В этих условиях достигается максимальная точность идентификации до 96,7% при средней скорости обработки одного объекта менее 0,5 с. Дополнительно подтверждена устойчивость системы к температурным колебаниям в диапазоне от -10°C до $+45^\circ\text{C}$, что расширяет область её применения в животноводческих комплексах.

Таким образом, результаты исследований показали, что разработанная система идентификации животных обладает высокой точностью, стабильностью и устойчивостью к внешним воздействиям, соответствует требованиям промышленной эксплуатации и может быть рекомендована к внедрению. Проведённая апробация продемонстрировала высокий уровень готовности технологии к серийному использованию и возможность дальнейшего масштабирования без потери качества работы, что подтверждается актами внедрения системы в ООО «Башкирская мясная компания» и ООО «Агромилк»

Глава 5. Технико-экономическая оценка применения системы идентификации сельскохозяйственных животных на предприятиях АПК

5.1 Оценка готовности системы

Для оценки работоспособности и эффективности предложенной системы идентификации была проведена её апробация в производственных условиях, приближенных к реальному производству. Апробация включала анализ влияния различных параметров на точность распознавания и вычислительную нагрузку. В данном разделе представлены результаты исследований по четырём ключевым направлениям: разрешение видеопотока, угол наклона камеры, частота кадров и уровень освещённости.

Для анализа влияния разрешения на вычислительные характеристики системы были проведены измерения времени обработки одного кадра. Результаты показали, что увеличение разрешения напрямую влияет на рост вычислительных затрат. На рисунке (5.1) представлена зависимость времени обработки от разрешения видеопотока для различных производственных условий.




Рисунок 5.1 — Время обработки одного кадра в зависимости от разрешения

Как видно из рисунка 5.1, при переходе разрешения от 480p к 1440p время обработки возросло почти в два раза, что необходимо учитывать при выборе оптимального режима работы системы. Таким образом, выбор разрешения должен балансировать между точностью идентификации и допустимой задержкой.

Одним из факторов, определяющих качество распознавания, является угол отклонения камеры от фронтальной позиции. На рисунке 5.2 показана зависимость точности идентификации от угла наклона.



Рисунок 5.2 — Влияние угла камеры на точность идентификации

Результаты на рисунке 5.2 демонстрируют, что при отклонении угла камеры до $\pm 10^\circ$ система сохраняет высокую точность (выше 90%), однако при больших углах наблюдается снижение точности до 86–87%. Это связано с искажением биометрических признаков и потерей информативности изображения.

Для оценки влияния частоты кадров (FPS) были проведены эксперименты с диапазоном от 10 до 40 кадров в секунду. Результаты показаны на рисунке 5.3.

Как видно, оптимальный диапазон частоты кадров составляет 15–25 FPS, при котором достигается максимальная точность распознавания (около 92–93%). Увеличение частоты кадров выше 30 FPS приводит к снижению точности из-за уменьшения времени обработки каждого кадра и, как следствие, неполной обработки признаков.




Рисунок 5.3 — Зависимость точности от частоты кадров

Важным параметром в условиях реального производства является уровень освещённости рабочей зоны. На рисунке 5.4 приведена зависимость точности от освещённости.




Рисунок 5.4 — Влияние освещённости на точность идентификации

Анализ результатов показал, что недостаточная освещённость (60%) приводит к снижению точности до 88%. При увеличении уровня освещения точность растёт и достигает максимальных значений (свыше 92%) при 100%

освещённости. Таким образом, корректная организация освещения рабочего пространства является важным фактором для обеспечения стабильной работы системы.

Результаты экспериментов показали, что на точность и производительность системы значительное влияние оказывают параметры видеопотока, угол наклона камеры, частота кадров и освещённость. Для обеспечения оптимального функционирования системы рекомендуется использовать разрешение 720p или 1080p, частоту кадров 20–25 FPS, угол отклонения камеры не более $\pm 10^\circ$ и освещённость, близкую к 100%. Проведённая апробация убедительно показала, что разработанная система может эффективно функционировать в условиях реального производственного процесса, обеспечивая стабильную работу при нагрузке до 10 000 операций в сутки. Экспериментальные исследования позволили определить оптимальные режимы и параметры эксплуатации, при которых достигается точность идентификации до 96,7 % при средней скорости обработки одного объекта менее 0,5 с. Дополнительно установлено, что система сохраняет корректность работы при колебаниях внешней температуры в диапазоне от -10°C до $+45^\circ\text{C}$, что подтверждает её устойчивость к внешним воздействиям и применимость в различных производственных условиях. Показатели производительности и надёжности полностью соответствуют установленным нормативным требованиям. Совокупность полученных результатов свидетельствует о высокой степени готовности системы к промышленному внедрению и создаёт предпосылки для её дальнейшего масштабирования.

5.2 Экономическая оценка использования системы идентификации сельскохозяйственных животных в АПК

Современные системы идентификации животных представляют собой технологический прорыв в сельскохозяйственном учете и управлении производственными процессами [21; 58; 81]. Экономическая оценка таких систем требует комплексного подхода, учитывающего как прямые финансовые показатели, так и стратегические преимущества автоматизированного мониторинга [67; 69].

Ключевые аспекты оценки включают:

- Капитальные и операционные затраты на внедрение.

- Прямую экономию от сокращения потерь.
- Косвенные выгоды от улучшения управляемости.
- Долгосрочные эффекты повышения продуктивности.
- Сравнительную эффективность относительно традиционных методов.

Для проведения комплексного анализа эффективности внедрения системы используется комбинированная методика, включающая несколько групп показателей. В первую очередь рассматривались традиционные показатели, такие как годовая рентабельность системы (R), коэффициент возврата инвестиций (ROI) и срок окупаемости (T), которые позволяют количественно оценить финансовую отдачу от инвестиций.

Во вторую группу были включены специфические отраслевые метрики, отражающие влияние внедрения системы на производственные процессы. К ним относятся снижение коэффициента конверсии кормов, повышение сохранности поголовья, увеличение среднесуточных привесов и сокращение трудозатрат на учетные операции. Эти показатели позволяют оценить эффективность управления животноводческим процессом и экономический эффект от оптимизации технологических операций [9; 76].

Третья группа показателей связана с качественными преимуществами внедрения системы. Сюда относятся улучшение прослеживаемости продукции, повышение точности ведения племенного учета и создание возможностей для прецизионного управления. Анализ этих аспектов позволяет выявить стратегические преимущества системы, выходящие за рамки чисто финансовых и производственных показателей, и оценить её влияние на качество управления и устойчивость производства [52; 53; 70; 71].

Что касается оценки эффективности свиноводческих комплексов, то основным фактором влияющим на эффективность функционирования системы считается высокая плотность размещения животных, что требует особого подхода к автоматизации процессов учета и управления [39; 73; 74]. Внедрение современных систем управления позволяет значительно повысить эффективность работы комплекса за счет эффекта масштаба [31; 49], особенно при автоматизации учета [46; 47]. Важно отметить, что при увеличении масштаба работы комплекса достигается оптимизация процессов кормления, ветеринарного контроля и учета животных [25; 75; 78].

В молочном скотоводстве система позволяет осуществить контроль индивидуальных продуктивных качеств, оптимизацию рационов, а также повышать качество генетической работы.

Внедрение системы идентификации животных создает значительные синергетические эффекты [30] при интеграции с другими технологическими решениями в АПК [8], что существенно повышает общую экономическую эффективность и управляемость производства [10; 29].

В процессе внедрения системы интеграции различных технологических компонентов в животноводческих хозяйствах необходимо учитывать несколько ключевых аспектов, охватывающих как автоматизацию процессов, так и улучшение качества учета и анализа данных [20; 72]. Одним из важных направлений является интеграция с автоматизированными системами кормления, которая позволяет обеспечивать точный учет индивидуального потребления корма. Важной функцией является автоматическая корректировка рационов на основе данных идентификации животных, что способствует снижению перерасхода кормов на 15-20%. Также необходимо отметить важность синхронизации данных в реальном времени для обеспечения актуальности информации и своевременного принятия решений.

Взаимодействие с умными поилками и системой климат-контроля предоставляет значительные возможности для персонализированного учета водопотребления, что также способствует оптимизации расхода ресурсов. Адаптация микроклимата с учетом перемещений животных и динамическое зонирование помещений являются необходимыми мерами для обеспечения комфортных условий и повышения общей продуктивности.

Кроме того, необходимо предусмотреть связь системы идентификации животных с ERP-системами предприятия, что позволит автоматически обновлять данные о поголовье, продуктивности и ветеринарном статусе животных. Это обеспечит возможность сквозной аналитики по цепочке: от идентификации животных до анализа экономических показателей, что в свою очередь позволит принимать более обоснованные управленческие решения. Важным аспектом является возможность интеграции с широко используемыми системами, такими как «Пульс.ЦСС», «1С:Предприятие 8. ERP Агропромышленный комплекс», что обеспечит дополнительную гибкость в работе с данными.

Еще одной важной составляющей является интеграция с ФГИС, которая позволяет автоматизировать процессы формирования отчетности. Это включа-

ет в себя создание ветеринарных свидетельств, прослеживаемость движения поголовья и ведение племенных книг. Внедрение такой системы позволит снизить трудозатраты на подготовку отчетности на 60-80%, что приведет к значительной экономии ресурсов.

Кроме того, в рамках дополнительных интеграционных возможностей можно выделить использование систем предиктивной аналитики здоровья, платформ для геномной селекции и мобильных приложений для сотрудников, что улучшает взаимодействие и контроль на всех уровнях предприятия.

Технические аспекты интеграции также имеют решающее значение. Важными параметрами являются использование единого протокола обмена данными (например, JSON), наличие API для подключения сторонних систем, а также частота обновления данных, которая может варьироваться от 1 до 5 минут в зависимости от требований заказчика. Эти технические характеристики обеспечивают гибкость системы и ее способность работать в условиях динамично меняющихся данных.

К критическим факторам успешной интеграции относят:

1. Единое пространство идентификаторов.
2. Стандартизованные форматы данных.
3. Регламенты синхронизации информации.

Основные затраты на внедрение представлены в таблице 5.1.

Таблица 5.1 — Первоначальные затраты на внедрение системы

Статья затрат	Сумма, руб.	Срок службы
Оборудование (камеры, датчики)	450 000	5 лет
Программное обеспечение	150 000	3 года
Монтаж и настройка	75 000	-
Обучение персонала	30 000	-
Итого	705 000	-

Оборудование включает в себя: промышленный тепловизор, исходные материалы для разработки и тестирования меток (резисторы, источники питания, ИК-диоды и т.д.).

Основные направления получения экономии:

— Снижение потерь кормов (10-15%):

$$E_{feed} = Feed \times V_{loss} \times N_{livestock} \quad (5.1)$$

где f_{eed} — цена 1 кг корма, V_{loss} — объем потерь на 1 голову, $N_{livestock}$ — поголовье.

- Оптимизация труда:
 - Сокращение времени учета на 70%.
 - Уменьшение персонала.

Годовая экономия от внедрения системы в репродукторе свиноводческого комплекса представлена в таблице 5.2.

Таблица 5.2 — Расчет годовой экономии

Статья экономии	Сумма, руб.
Экономия кормов	650 000
Снижение падежа (2,5%)	240 000
Экономия оплаты труда	350 000
Итого	1 240 000

В рамках оценки эффективности внедрения системы были проведены расчеты ключевых показателей, таких как срок окупаемости и рентабельность. Срок окупаемости системы рассчитывается как отношение первоначальных затрат к ежегодной экономии, что позволяет определить время, необходимое для возврата вложенных средств. В данном случае расчёт производится по формуле:

$$T_{\text{ок}} = \frac{K}{E_{\text{year}}} = \frac{705\,000}{1\,240\,000} \approx 0,56 \text{ лет} \approx 7 \text{ мес}, \quad (5.2)$$

где K — первоначальные затраты, а E_{year} — годовая экономия. Полученный результат указывает на высокую финансовую привлекательность системы, поскольку срок окупаемости составляет всего 7 месяцев, что свидетельствует о быстрой отдаче вложений.

Годовая рентабельность системы рассчитывается как отношение годовой экономии к первоначальным затратам, умноженное на 100%. В данном случае, согласно расчётам:

$$R = \frac{E_{\text{year}}}{K} \times 100\% = 175,9\%, \quad (5.3)$$

где E_{year} — годовая экономия, а K — первоначальные затраты. Полученное значение рентабельности в 175,9% подтверждает высокую доходность от внедрения системы, что делает её экономически привлекательной для потенциальных инвесторов.

Особенно значительный экономический эффект наблюдается при использовании системы на крупных свиных комплексах с большим поголовьем [34], где она позволяет существенно сократить затраты на кормление и другие эксплуатационные расходы. Это ещё раз подчёркивает её эффективность в условиях крупных производств.

Внедрение системы требует относительно небольших первоначальных вложений. Несмотря на высокую эффективность, важным аспектом является наличие низких барьеров для входа в процесс её внедрения.

Ключевым условием успешности внедрения системы является правильная эксплуатация, что напрямую зависит от соблюдения регламентов и инструкций по её эксплуатации. Это подчёркивает необходимость качественного обучения персонала и строгого контроля за эксплуатационными процессами.

Предлагаемая система является оптимальной для средних и крупных свиных комплексов, поскольку она предоставляет возможности для автоматизации процессов учёта и управления, что значительно улучшает производственные показатели. Максимальная автоматизация процессов учёта позволяет осуществлять полный контроль за кормлением, состоянием здоровья животных и другими важными производственными показателями, что в свою очередь способствует улучшению эффективности управления на всех уровнях.

Важнейшим этапом оценки эффективности разработанной системы идентификации сельскохозяйственных животных является сравнение динамики окупаемости различных подходов к идентификации животных в зависимости от поголовья свиней (рисунок 5.5).

Анализ показывает, что для животноводческих предприятий с поголовьем менее 3 тысяч голов в свиноводстве при продуктивности ниже 350–400 грамм привеса в сутки (в среднем для всех половозрастных групп животных) и менее 200 голов в молочном скотоводстве при продуктивности ниже 6,5 – 7 тонн молока в год бирки имеют наилучшие показатели окупаемости, но менее эффективны с точки зрения мониторинга. При поголовье более 3 тысяч свиней и средней продуктивности выше 400 грамм привеса в сутки и более 200 голов молочного стада с удоями выше 7 тонн молока в год система идентификации на базе инфракрасной идентификации и искусственного интеллекта становится наиболее оптимальной. RFID-технологии демонстрируют нелинейную зависимость, но с большим сроком окупаемости.




Рисунок 5.5 — Сравнение динамики окупаемости различных подходов к идентификации животных

Для оценки целесообразности инвестирования в систему используется коэффициент возврата инвестиций (ROI), который является ключевым показателем для анализа эффективности вложений. Он позволяет определить, насколько выгодным является проект с учетом как начальных затрат, так и ежегодной экономии, которую принесет внедрение системы. Формула для расчёта этого коэффициента имеет вид (5.4):

$$ROI = \frac{E_{\text{year}} - K}{K} \times 100\%, \quad (5.4)$$

где E_{year} — это экономия, достигаемая в год, а K — это затраты на внедрение системы в первый год. Этот коэффициент помогает оценить, за какой период система окупит первоначальные инвестиции и начнёт приносить чистую прибыль.

Коэффициент ROI является важным инструментом при принятии решения о целесообразности инвестиций в новые технологии. Чем выше значение ROI, тем более привлекательным и выгодным является проект. Высокий коэффициент свидетельствует о существенном снижении расходов и повышении производственных показателей благодаря внедрению системы, что подтверждается значительной экономией и сравнительно небольшими первоначальными затратами.

Важным аспектом является то, что ROI позволяет учитывать не только прямые финансовые выгоды, такие как снижение затрат на материалы и повышение производительности, но и более широкие эффекты, такие как оптимизация рабочих процессов и сокращение потерь. Следует отметить, что коэффициент может варьироваться в зависимости от масштабов внедрения, специфики производства и уровня готовности персонала, что требует индивидуального подхода к каждому проекту.

Таким образом, расчёт коэффициента возврата инвестиций является важным инструментом для комплексной оценки финансовых результатов и минимизации рисков. Он позволяет обоснованно определить, насколько эффективно будет использование системы в долгосрочной перспективе и помогает оптимизировать процессы распределения ресурсов, что способствует более обоснованному принятию управленческих решений.

В таблице 5.3 представлены данные о расчетах экономического эффекта от интеграции различных систем. Для каждой системы указаны показатели годовой экономии на 1000 голов и коэффициент возврата инвестиций (ROI). Наибольший экономический эффект наблюдается при комплексной интеграции, где удельная годовая экономия составляет от 800 до 1200 тысяч рублей, а ROI варьируется от 200 до 250%. Внедрение автокормления позволяет получить экономию в пределах 450-600 тысяч рублей с ROI от 140 до 180%. Интеграция ERP-системы приносит экономию от 200 до 350 тысяч рублей, а ROI составляет 90-120%. Наименьшие показатели экономии и ROI наблюдаются при интеграции с государственными информационными системами, где годовая экономия колеблется от 150 до 250 тысяч рублей, а ROI составляет 70-90%.

Таблица 5.3 — Пример расчета показателей экономической эффективности от интеграции системы в свиноводческих комплексах

Вид интеграции	Удельная годовая экономия (1000 голов)	ROI
Автокормление	450-600 т.р.	140-180%
ERP-система	200-350 т.р.	90-120%
ФГИС	150-250 т.р.	70-90%
Комплексная	800-1200 т.р.	200-250%

Перспективным направлением развития является создание единой цифровой платформы управления животноводством, объединяющей все компоненты в экосистему единой фермерской системы учета.

В процессе внедрения новой системы могут возникать различные ограничения, которые можно классифицировать по нескольким категориям. Технологические ограничения включают в себя несколько факторов, которые непосредственно влияют на эффективность функционирования системы. Среди них можно выделить зависимость от качества интернет-соединения, что может повлиять на стабильность работы системы в условиях нестабильных сетевых подключений. Также важным фактором является чувствительность системы к условиям освещения, что может ограничивать её применимость в условиях, где освещённость недостаточна или изменяется во времени. Экономические ограничения связаны со стоимостью первоначальных инвестиций, которые необходимы для установки и настройки системы. Это может стать препятствием для малых и средних предприятий, не имеющих значительных финансовых ресурсов. Кроме того, важным аспектом является необходимость обучения персонала, что подразумевает дополнительные затраты на подготовку сотрудников для эффективного использования системы. Организационные ограничения могут проявляться в виде сопротивления изменениям со стороны сотрудников, что является довольно распространённой проблемой при внедрении новых технологий в сельском хозяйстве. Для успешной интеграции системы важно также учесть необходимость адаптации существующих рабочих процессов, что потребует времени и усилий для пересмотра и оптимизации текущих методов работы.

Эти ограничения, хотя и представляют собой потенциальные сложности, могут быть преодолены при правильном подходе к внедрению, включая качественное планирование, обучение персонала и адаптацию инфраструктуры.

Таким образом, разработанная система идентификации демонстрирует высокую экономическую эффективность (ROI 70-250%); быструю окупаемость (от 7 месяцев); значительный потенциал для масштабирования; стратегические преимущества в управлении.

Дальнейшее развитие технологии должно быть направлено на снижение стоимости оборудования и упрощение процессов внедрения для малых сельхозпредприятий [106].

5.3 Выводы по главе

В результате проведённого экономического анализа внедрения системы идентификации сельскохозяйственных животных на примере свиноводческого комплекса установлено, что использование технологий компьютерного зрения и инфракрасной идентификации обеспечивает значительное повышение эффективности производственных процессов и сокращение издержек. Экономическая оценка показала, что система способствует оптимизации управления животноводческими предприятиями за счёт снижения потерь кормов, уменьшения падежа поголовья и сокращения затрат на учётно-контрольные операции. Рассчитанные показатели, подтверждают высокую инвестиционную привлекательность системы: срок окупаемости составляет от 7 месяцев в зависимости от масштаба предприятия; годовая рентабельность системы составляет 175,9%.

Существенная экономия достигается за счёт автоматизации учёта, что позволяет уменьшить численность обслуживающего персонала и сократить расходы на оплату труда. Анализ показал, что внедрение системы способствует не только прямому снижению затрат, но и косвенным улучшениям производственных показателей, включая повышение сохранности животных, улучшение прослеживаемости продукции и оптимизацию процессов кормления.

Дополнительные выгоды связаны с возможностью интеграции системы с другими технологическими решениями — автоматизированными системами кормления, климат-контроля, ERP-платформами и ФГИС. Такая интеграция формирует единую информационную среду управления, что повышает прозрачность процессов и позволяет оперативно принимать управленческие решения на основе объективных данных. При комплексной интеграции достигается максимальный эффект, выражающийся в годовой экономии от 800 тысяч до 1,2 миллиона рублей на каждую тысячу голов, при коэффициенте возврата инвестиций до 250%.

В ходе анализа также были определены основные технологические, экономические и организационные ограничения, влияющие на эффективность внедрения. К ним относятся зависимость от качества интернет-соединения, необходимость первоначальных инвестиций и потребность в обучении персонала. Однако эти факторы могут быть компенсированы за счёт постепенного

внедрения, модульной архитектуры системы и проведения адаптационных мероприятий.

Полученные результаты подтверждают, что система идентификации животных является не только технически, но и экономически целесообразным решением, особенно для средних и крупных предприятий. Она обеспечивает высокую отдачу инвестиций, быстрый срок окупаемости и значительный потенциал для масштабирования. В долгосрочной перспективе внедрение таких систем способствует формированию интеллектуальных производственных комплексов, повышению конкурентоспособности агробизнеса и переходу к цифровым моделям управления в рамках концепции «умного сельского хозяйства».

Заключение

В диссертационной работе разработана интеллектуальная система идентификации сельскохозяйственных животных, основанная на использовании инфракрасной детекции и методов искусственного интеллекта. Предложенная система обеспечивает бесконтактную, высокоточную и оперативную идентификацию сельскохозяйственных животных [2]. В ходе исследования обоснован выбор инфракрасного диапазона и архитектуры модели искусственного интеллекта, реализована программно-аппаратная платформа, а также проведена апробация системы идентификации в лабораторных и производственных условиях.

Разработанный подход к идентификации сочетает в себе технологии инфракрасной идентификации и алгоритмы компьютерного зрения на базе нейросетевой модели YOLO11, прошедшей этап оптимизации посредством дистилляции. Проведено компьютерное моделирование различных сценариев освещённости и плотности движения животных. Система успешно прошла лабораторные испытания и производственную валидацию, подтвердив стабильность функционирования в реальной среде.

Кроме того, выполнена экономическая оценка внедрения системы на предприятиях АПК, доказавшая её рентабельность и практическую значимость для развития цифрового сельского хозяйства. Предложенное решение способствует снижению удельных годовых затрат (800 тыс.—1,2 млн. рублей на 1000 голов) при условии комплексной интеграции, повышению точности мониторинга, улучшению условий содержания животных.

Таким образом, получены следующие результаты:

1. Выполнен анализ 8 основных существующих методов идентификации сельскохозяйственных животных, выявлены их ограничения, доказана актуальность перехода к бесконтактным технологиям на основе инфракрасной детекции.
2. Подтверждена технологическая применимость инфракрасной системы идентификации для сельскохозяйственных животных, определены физико-технические параметры системы, включая длину волны (700нм—1500нм), мощность излучения (50–300 mW) и характеристики ИК-приемников (0,35–0,6 А/Вт) с расчетной погрешностью $\pm 0,5$ метра

- и дополнительными погрешностями позиционирования ± 2 см, систематической погрешностью скорости $\pm 0,1$ м/с. Для качественной работы системы определена граница точности, которая составила 70%. Благодаря выбранным современным методам аугментации изображений, обучающий датасет был увеличен с 5000 изображений до 15000, что позволило увеличить точность при обучении на 20%.
3. Разработана и обоснована методология сбора и предварительной обработки датасета, включающего 5000 исходных изображений, а также дополнительных аугментированных наборов данных объемом 15 000 изображений, предназначенных для обучения моделей искусственного интеллекта.
 4. Проведён анализ и адаптация методов искусственного интеллекта к задаче идентификации сельскохозяйственных животных. Реализован эффективный алгоритм на основе модели YOLO11, оптимизированной посредством дистилляции, позволяющей работать в реальном времени. Достигнутая точность составляет 92% со скоростью обработки 45 мс.
 5. Разработан программно-аппаратный комплекс, включающий инфракрасные датчики, видеомодули и блок обработки, способный функционировать автономно и интегрироваться в цифровые платформы сельскохозяйственных предприятий «Пульс.ЦСС», «1С:Предприятие 8. ERP Агропромышленный комплекс».
 6. Проведено компьютерное моделирование различных сценариев эксплуатации системы, выявлены предельные значения точности при изменении условий внешней среды и плотности потока животных. При количестве объектов более 15 точность определения составляет 85,0% со средним временем задержки детекции 62 мс. при условии использования минимально необходимых вычислительных мощностей. При нормальном освещении медианное значение точности составляет около 89,5%, при этом наблюдается относительно широкий разброс значений. В условиях перепадов освещённости медиана повышается до 90,5%, что можно объяснить адаптацией системы к изменяющимся условиям.
 7. Выполнены лабораторные и производственные испытания в 2 компаниях (ООО «Башкирская мясная компания» и ООО «Агромилк»), подтвердившие устойчивость системы к внешним помехам, статистиче-

ская обработка данных показала достоверность результатов на уровне статистической значимости $\alpha = 0,05$.

8. Выполнена экономическая оценка внедрения системы на предприятии: зафиксировано снижение затрат на идентификацию и обслуживание, рост эффективности производственного мониторинга, снижение потерь из-за ошибок идентификации. Полученное во время апробации в идеальных условиях значение рентабельности в размере 175,9% свидетельствует о высокой эффективности и значительном уровне доходности от внедрения системы, что подтверждает её экономическую целесообразность и инвестиционную привлекательность.

В качестве перспектив дальнейших исследований предлагается:

- реализация масштабируемой версии системы с поддержкой облачной обработки и интеграции в ERP-системы агропредприятий;
- расширение функционала системы для биометрического мониторинга состояния сельскохозяйственных животных (анализ термограммы, выявление воспалений и нарушений температурного фона);
- адаптация системы под различные виды сельскохозяйственных животных и условий содержания (открытые пастбища, интенсивные фермы);
- разработка модуля автоматического выявления отклонений и передачи оповещений в режиме реального времени;
- внедрение REST API-интерфейса для подключения внешних аналитических систем и написание веб-сервиса для управления системой идентификации и получения отчётности.

Все представленные в работе разработки выполнены с использованием открытого программного обеспечения под свободной лицензией, совместимой с GNU GPL. Исследования и эксперименты проводились в среде Ubuntu 22.04 с использованием Python 3.14 и библиотек: OpenCV, PyTorch, NumPy, Matplotlib, SciPy, pandas и др.

Предложенное решение в полной мере соответствует требованиям цифровизации АПК и открывает возможности для построения автономных интеллектуальных систем учёта, мониторинга и управления животноводческими комплексами.

Автор выражает благодарность и большую признательность академику РАН О. Н. Дидманидзе и доценту М. Н. Степанцевич за поддержку, помощь и научное руководство

Список сокращений и условных обозначений

3D-моделирование	трехмерное моделирование
<i>FN</i>	число ложноотрицательных примеров (False Negatives)
<i>FP</i>	число ложноположительных примеров (False Positives)
<i>TN</i>	число правильно классифицированных отрицательных примеров (True Negative)
<i>TP</i>	число правильно классифицированных положительных примеров (True Positives)
AP	средняя точность (Average Precision)
Faster R-CNN	Faster Region-based Convolutional Neural Network (Более быстрая сверточная нейронная сеть на основе регионов)
FPS	количество кадров в секунду
IoU	оценка степени пересечения предсказанного ограничивающего прямоугольника (bounding box) с истинным (Intersection over Union)
Precision	Точность
R-CNN	Region-based Convolutional Neural Network (Свёрточная нейронная сеть на основе регионов)
Recall	Полнота
RFID	радиочастотная идентификация
RGB	красный-зеленый-синий
ROC	рабочая характеристика приёмника
ROI	коэффициент окупаемости инвестиций (return on investment)
YOLO	«You Only Look Once»
АПК	агропромышленный комплекс
ИИ	искусственный интеллект
ИК-волна	инфракрасная волна
ИК-диод	инфракрасный диод

ИК-идентификация	инфракрасная идентификация
ИК-метка	инфракрасная метка
ИК-сигнал	инфракрасный сигнал
КТ	компьютерная томография
МРТ	магнитно-резонансная томография
ФГИС	Федеральная государственная информационная система

Список литературы

1. Абдрахимов, Д. А. Технология идентификации животных на основе искусственного интеллекта и инфракрасной системы детекции / Д. А. Абдрахимов // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. — 2024. — Т. 204. — С. 1—11.
2. Абдрахимов, Д. А. Технология инфракрасной идентификации в задаче детекции сельскохозяйственных животных / Д. А. Абдрахимов // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. — 2025. — Т. 207. — С. 279—292.
3. Абдрахимов, Д. А. Анализ способов внесения жидких органических удобрений / Д. А. Абдрахимов, Н. Козлов // Развитие научно-инновационного потенциала аграрного производства: проблемы, тенденции, пути решения. Сборник научных трудов по материалам Международной научно-практической конференции. — Тверь, 2022. — С. 121—123.
4. Абдрахимов, Д. А. Актуальность разработки сервиса инфракрасной системы идентификации свиней на основе искусственного интеллекта / Д. А. Абдрахимов, М. Н. Степанцевич // Управление земельно-имущественным комплексом в условиях цифровизации агропромышленного производства : Материалы Всероссийской научно-практической конференции, посвященной 80-летию высшего землеустроительного образования в Пермском крае. — Пермь: ИПЦ Прокрость, 2024. — С. 13—18.
5. Автоматизация процесса прогнозирования данных / О. А. Иващук, О. Д. Иващук, С. В. Игрунова [и др.] // Известия Юго-Западного государственного университета. — 2025. — Т. 29, № 2. — С. 166—185.
6. Алекперов, К. Перспективы развития свиноводства в 21 веке / К. Алекперов // Свиноводство. — 2002. — № 1. — С. 18—28.
7. Алексей Макаревич. Автоматическая идентификация — фаворит мировой торговли / Алексей Макаревич // Наука и инновации. — 2006. — 10 (44). — С. 63—66. — URL: <https://cyberleninka.ru/article/n/avtomaticheskaya-identifikatsiya-favorit-mirovoy-torgovli> (дата обр. 15.10.2024) ; Number: 10 (44) Place: Республика Беларусь, Минск

Publisher: Республиканское унитарное предприятие «Издательский дом «Белорусская наука».

8. Анализ работы и разработка требований к роботизированным доильным системам на примере хозяйства Ивановской области / Л. В. Гуркина [и др.] // Аграрный вестник Верхневолжья. — 2019. — 4(29). — С. 102—111. — EDN: ZAGZFF.
9. Аспекты интеграции информационных систем сельскохозяйственных предприятий / Т. Ф. Череватова [и др.] // Научное обозрение: теория и практика. — 2021. — Т. 11, 8(88). — С. 2397—2414.
10. Барабанов, Д. В. Перспективы применения нейронных сетей для машинного зрения роботизированной установки преддоильной подготовки вымени коров / Д. В. Барабанов, М. А. Керимов // Повышение эффективности и техническая модернизация технологических процессов, машин, энергетического оборудования при производстве и переработке сельскохозяйственной продукции: материалы национальной научно-практической конференции в рамках 33-й Международной агропромышленной выставки-ярмарки АГРОРУСЬ 2024, Санкт-Петербург — Пушкин, 29 августа 2024 года. — Санкт-Петербург — Пушкин : Санкт-Петербургский государственный аграрный университет, 2024. — С. 12—18. — EDN: КАКТNV.
11. Бекенёв, В. А. Технология разведения и содержания свиней: Учебное пособие / В. А. Бекенёв. — СПб : Издательство «Лань», 2012. — 416 с.
12. Бессимптомная гиперурикемия у мужчин молодого возраста, выявленная в период диспансеризации: распространенность и ассоциация с популяционными заболеваниями / М. М. Мастерова [и др.] // Терапия. — 2024. — Т. 10. — С. 74—81.
13. Бижаев, А. В. Автоматизированные системы управления мобильными энергетическими средствами: Лабораторный практикум / А. В. Бижаев, С. Н. Девянин, В. Л. Чумаков. — Москва : Калужский филиал федерального государственного бюджетного образовательного учреждения высшего образования "Российский государственный аграрный университет - МСХА имени К.А. Тимирязева", 2023. — С. 50. — EDN KBECZY.
14. Боярский, Р. Проблемы дальнейшего развития и интенсификации свиноводства / Р. Боярский // Свиноводство. — 2004. — № 6. — С. 24—26.

15. Бресь, К. И. Воспроизводство свиней в промышленных условиях / К. И. Бресь // Материалы Международного научного симпозиума, посвященного 150-летию со дня рождения выдающегося ученого в области зоотехнии академика Е.Ф. Лискуна "Достижения зоотехнической науки в решении актуальных задач животноводства и аквакультуры". — Москва, 2023. — С. 49—53.
16. Вальехо, М. П. Р. Автоматизированное построение индикаторной диаграммы четырёхтактного рядного двигателя / М. П. Р. Вальехо, С. Н. Де-вянин. — 2021. — № 2021662573 : заявл. 10.08.2021 : опубл. 16.08.2021 : заявитель федеральное государственное автономное образовательное учреждение высшего образования «Российский университет дружбы народов». EDN AAQCHL. Свидетельство о государственной регистрации программы для ЭВМ № 2021663396 Российская Федерация.
17. Вахрушева А. А. Технологии позиционирования в режиме реального времени / Вахрушева А. А. // Вестник СГУГиТ (Сибирского государственного университета геосистем и технологий). — 2017. — Т. 22, № 1. — С. 170—177. — URL: <https://cyberleninka.ru/article/n/tehnologii-pozitsionirovaniya-v-rezhime-realnogo-vremeni> (дата обр. 15.10.2024) ; Number: 1 Place: Россия, Новосибирск Publisher: Федеральное государственное бюджетное образовательное учреждение высшего образования «Сибирский государственный университет геосистем и технологий».
18. Гадд, Д. Компьютерное жидкое кормление: прошлое, настоящее и будущее. О чем не говорится в учебниках / Д. Гадд // Свиноводство. — 2010. — № 2. — С. 21—23.
19. Гамов, А. А. Автоматизация управления двигателем для экономии топлива и сокращения вредных выбросов в атмосферу в агропромышленном комплексе / А. А. Гамов, Н. Н. Пуляев // Чтения академика В. Н. Болтинского : сборник статей, Москва, 22–23 января 2025 года. — Москва : ООО «Сам Полиграфист», 2025. — С. 144—152. — EDN HACGHB.
20. Горбачев, М. И. Анализ развития и практический опыт применения цифровых технологий в АПК РФ / М. И. Горбачев, М. Н. Кушнарева // Доклады ТСХА. Т. 292. — Москва : Российский государственный аграрный университет — МСХА им. К. А. Тимирязева, 2020. — С. 390—393.
21. Д.В, Х. Электронная идентификация животных / Х. Д.В, М. А.С // Ученые записки Казанской государственной академии ветеринарной ме-

- дицины им. Н. Э. Баумана. — 2011. — Т. 206, № 2. — С. 236—240. — URL: <https://cyberleninka.ru/article/n/elektronnaya-identifikatsiya-zhivotnyh-1> (дата обр. 15.10.2024) ; Number: 2 Place: Россия, Казань Publisher: Федеральное государственное бюджетное образовательное учреждение высшего образования «Казанская государственная академия ветеринарной медицины им. Н.Э. Баумана».
22. Дидманидзе, О. Н. Особенности применения датчиков в автоматической системе движения шагающих машин / О. Н. Дидманидзе, Я. Г. Митягина, Ю. Г. Алейников // Международный технико-экономический журнал. — 2012. — № 5. — С. 72—75. — EDN PUQIWX.
 23. Дидманидзе, О. Н. Испытания электрического транспортно-технологического средства сельскохозяйственного назначения по оценке потребительских свойств / О. Н. Дидманидзе, Р. С. Федоткин, В. А. Крючков // Проблемы машиностроения и автоматизации. — 2024. — № 4. — С. 4—15. — EDN QMNYBE.
 24. Егоров, Р. Н. Мониторинг состояния дорожного покрытия с помощью получаемой информации от объектов движения / Р. Н. Егоров, Н. Н. Пуляев, Д. А. Москвичев // Чтения академика В. Н. Болтинского : сборник статей, Москва, 22–23 января 2025 года. — Москва : ООО «Сам Полиграфист», 2025. — С. 188—193. — EDN FPZTTN.
 25. Инновационные технологии содержания мелкого рогатого скота: аналитический обзор / Ю. А. Юлдашбаев [и др.]. — Москва : РосНИИИТЭИ Агропрома, 2020. — 80 с. — EDN: YYRMXP.
 26. Искусственный интеллект в научно-техническом развитии сельского хозяйства / Н. П. Мишуров [и др.] // Научно-информационное обеспечение инновационного развития АПК: Материалы XV Международной научно-практической конференции. — р.п. Правдинский, Московская область : Российский НИИ информации и технико-экономических исследований по инженерно-техническому обеспечению АПК, 2023. — С. 78—83.
 27. ИТС 41-2017. Интенсивное разведение свиней. Информационно-технический справочник по наилучшим доступным технологиям. — 2017. — URL: <http://www.gost.ru> ; Дата обращения: 16.08.2025.
 28. К вопросу разработки и стандартизации цифровых решений для обеспечения биобезопасности свиноводческой отрасли стран БРИКС / М. Н. Сте-

- панцевич [и др.] // Управление рисками в АПК. — 2024. — 2(52). — С. 96—106.
29. Керимов, М. А. Исследование системы машинного зрения роботизированной установки преддоильной подготовки вымени коров / М. А. Керимов, Н. В. Муханов, Д. В. Барабанов // АгроЭкоИнженерия. — 2024. — 1(118). — С. 118—135. — EDN: GYKFJV.
 30. Керимов, М. А. Программное обеспечение системы машинного зрения роботизированной установки преддоильной подготовки вымени коров / М. А. Керимов, Н. В. Муханов, Д. В. Барабанов // Совершенствование инженерно-технического обеспечения производственных процессов и технологических систем: материалы национальной научно-практической конференции с международным участием, Оренбург, 03 февраля 2023 года. — Оренбург : Оренбургский государственный аграрный университет, 2023. — С. 8—12. — Издательство «Перо». — EDN: DMONDN.
 31. Ковалев, Ю. Свиноводство России: новая реальность / Ю. Ковалев // Животноводство России. — 2020. — № 7. — С. 20—23.
 32. Компьютерное зрение: концепт, функционально-целевое назначение, структура, регуляторика / Понкин И. В. [и др.] // International Journal of Open Information Technologies. — 2024. — Т. 12, № 5. — С. 57—66. — URL: <https://cyberleninka.ru/article/n/kompyuternoe-zrenie-kontsept-funktsionalno-tselevoe-naznachenie-struktura-regulyatorika> (дата обр. 15.10.2024) ; Number: 5 Place: Россия, Москва Publisher: Лаборатория Открытых Информационных Технологий факультета ВМК МГУ им. М.В. Ломоносова.
 33. Кормановский, Л. П. Приоритетные направления роботизации процессов молочных ферм / Л. П. Кормановский, Ю. А. Цой, В. В. Кирсанов // Инновации в сельском хозяйстве. — 2018. — 2(27). — С. 334—339. — EDN VAQOIK.
 34. Красновская, Е. Ключевые факторы повышения продуктивности в свиноводстве / Е. Красновская // Свиноводство. — 2020. — № 2. — С. 34—35.
 35. Ландсберг Г. С. Оптика. Учеб. пособие: Для вузов. / Ландсберг Г. С. — 6-е изд. — ФИЗМАТЛИТ, 2003.
 36. Макаров А.С. Системы и способы идентификации животных в обеспечении эпизоотического благополучия региона / Макаров А.С, Василевский Н.М, Хайруллина Д.В // Ученые записки Казанской государственной ака-

- демии ветеринарной медицины им. Н. Э. Баумана. — 2013. — Т. 215, № 3. — С. 202—206. — URL: <https://cyberleninka.ru/article/n/sistemy-i-sposoby-identifikatsii-zhivotnyh-v-obespechenii-epizooticheskogo-blagopoluchiya-regiona> (дата обр. 15.10.2024) ; Number: 3 Place: Россия, Казань Publisher: Федеральное государственное бюджетное образовательное учреждение высшего образования «Казанская государственная академия ветеринарной медицины им. Н.Э. Баумана».
37. Матвеев А. Н. Оптика: Учеб, пособие для физ. спец. вузов. / Матвеев А. Н. — 1985.
 38. Медхн, Т. А. Анализ взаимосвязи между мощностью и шириной захвата жатки и эффективности автоматизации рабочего процесса зерноуборочного комбайна / Т. А. Медхн, А. Г. Левшин // Международная научная конференция молодых учёных и специалистов, посвящённая 180-летию со дня рождения К.А. Тимирязева : Сборник статей, Москва, 05–07 июня 2023 года. — Москва : Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2023. — С. 478—483. — EDN WDOSXS.
 39. Методические рекомендации по технологическому проектированию свиноводческих ферм и комплексов Р Д-АПК 1.10.02.04-12. — 2012. — URL: <https://docs.yandex.ru> ; Утв. и введ. в действие Минсельхозом РФ 06.07.2012. Дата обращения: 16.08.2025.
 40. Методы нейросетевой детекции сельскохозяйственных животных в плотных динамических группах на изображениях / А. А. Жигалов [и др.] // Искусственный интеллект и принятие решений. — 2023. — № 1. — С. 55—66.
 41. Мищенко, А. Сравнение оборудования основных поставщиков, работающих на российском рынке в области радиочастотой идентификации / А. Мищенко // Сельскохозяйственный журнал. — 2014. — Т. 2, № 7. — С. 485—489. — URL: <https://cyberleninka.ru/article/n/cravnenie-oborudovaniya-osnovnyh-postavschikov-rabotayuschih-na-rossiyskom-rynke-v-oblasti-radiochastotoy-identifikatsii> (дата обр. 15.10.2024) ; Number: 7 Place: Россия, Ставрополь Publisher: Федеральное государственное бюджетное научное учреждение «Всероссийский научно-исследовательский институт овцеводства и козоводства».
 42. Мысик, А. Т. Современные тенденции развития животноводства в странах мира / А. Т. Мысик // Зоотехния. — 2010. — № 1. — С. 2—8.

43. Направления исследований при создании автоматизированных и роботизированных модулей доения коров / Ю. А. Иванов [и др.] // Вестник Всероссийского научно-исследовательского института механизации животноводства. — 2018. — 3(31). — С. 15—19. — EDN XZNYEH.
44. Национальная энциклопедия. Инфракрасное излучение / Национальная энциклопедия. — Казахстан : Қазақ энциклопедиясы, 2005.
45. Новиков В. Ю. Применение метода линейного дискриминантного анализа спектров отражения В ближней инфракрасной области для видовой идентификации рыб семейства лососёвые (salmonidae) / Новиков В. Ю., Рысакова К. С, Барышников А. В // Вестник Мурманского государственного технического университета. — 2021. — Т. 24, № 4. — С. 450—460. — URL: [https://cyberleninka.ru/article/n/primenenie-metoda-lineynogo-diskriminantnogo-analiza-spektrov-otrazheniya-v-blizhney-infrakrasnoy-oblasti-dlya-vidovoy](https://cyberleninka.ru/article/n/primenenie-metoda-lineynogo-diskriminantnogo-analiza-spektrov-otrazheniya-v-blizhney-infrakrasnoy-oblasti-dlya-vidovoy-identifikatsii-ryb-semejstva-lososyevye-salmonidae) (дата обр. 15.10.2024) ; Number: 4 Place: Россия, Мурманск Publisher: Федеральное государственное бюджетное образовательное учреждение высшего образования «Мурманский государственный технический университет».
46. Определение выхода мяса с помощью ультразвуковых сканеров «Скангрейд» и «Пиглог 105» / А. И. Рудь [и др.]. — 2011. — URL: <https://cyberleninka.ru/article/n/opredelenie-vyhoda-myasa-s-pomoschyu-ultrazvukovyh-skanerov-skangreyd-i-piglog-105> ; Перспективное свиноводство: теория и практика. №4. Дата обращения: 16.08.2025.
47. Определение площади мышечного глазка и выхода мяса с помощью ультразвуковых сканеров различного типа / А. И. Рудь [и др.] // Свиноводство. — 2011. — № 4. — С. 20—23.
48. Определение уровней цифровой зрелости / О. А. Моторин [и др.] // Техника и оборудование для села. — 2024. — 7(325). — С. 15—17.
49. Оптимизация размера групп молодняка свиней на дорасчивании / В. А. Безмен [и др.]. — 2020. — URL: <https://cyberleninka.ru/article/n/optimizatsiya-razmera-grupp-molodnyaka-sviney-na-doraschivanii> ; Актуальные проблемы интенсивного развития животноводства. №23(2). Дата обращения: 01.08.2025.
50. Осипов Ю. С. Большая российская энциклопедия / Осипов Ю. С. — Большая российская энциклопедия. — 2004.

51. Передовые достижения в применении автоматизации, роботизации и электротехнологий в АПК / под ред. И. Бородин [и др.]. — Москва : Общество с ограниченной ответственностью Мегаполис, 2019. — С. 320. — (Сборник статей научно-практической конференции, посвященной памяти академика РАСХН, д.т.н., профессора И.Ф. Бородина (90 лет со дня рождения), Москва, 01–02 октября 2019 года). — EDN UBMODR.
52. Плаксин, И. Е. Перспективные направления развития отрасли свиноводства в России / И. Е. Плаксин, С. И. Плаксин, А. В. Трифанов. — 2020. — URL: <https://cyberleninka.ru/article/n/perspektivnye-napravleniya-razvitiya-otrasli-svinovodstva-v-rossii>; АгроЭкоИнженерия. №2(103). Дата обращения: 20.06.2025.
53. Плаксин, И. Е. Тенденции и перспективы развития свиноводства в России / И. Е. Плаксин, С. И. Плаксин, А. В. Трифанов // АгроЭкоИнженерия. — 2022. — 1(110). — С. 155–168.
54. Подходы к биометрической детекции сельскохозяйственных животных на основе нейросетевого аппарата / А. А. Жигалов [и др.] // Информационные технологии в науке, образовании и производстве (ИТНОП-2023). Сборник трудов IX Международной научно-технической конференции. — Белгород, 2023. — С. 153–156. — URL: <https://www.elibrary.ru/item.asp?id=54318180>; ELibrary ID: 54318180.
55. Походня, Г. С. Свиноводство: учебное пособие / Г. С. Походня, А. Г. Нарижный, П. И. Бреславец. — М. : Колос, 2009. — 500 с.
56. Походня, Г. С. Влияние различных условий содержания на продуктивность ремонтных свинок / Г. С. Походня, Е. Г. Поморова // Ветеринария сельскохозяйственных животных. — 2007. — № 11. — С. 24–29.
57. Применение систем технического зрения для диагностики качества кормов КРС / В. В. Кирсанов [и др.] // Аграрная наука Евро-Северо-Востока. — 2021. — Т. 22, № 5. — С. 770–776. — EDN SYCRQP.
58. Р.С., К. Автоматизированная информационная система для учета чипированных животных / К. Р.С., М. А.А. // Вестник науки. — 2024. — Т. 3, 1 (70). — С. 668–672. — URL: <https://cyberleninka.ru/article/n/avtomatizirovannaya-informatsionnaya-sistema-dlya-ucheta-chipirovannyh-zhivotnyh> (дата обр. 15.10.2024) ; Number: 1 (70) Place: Россия, Тольятти Publisher: Рассказова Любовь Федоровна.

59. Регуляризирующие алгоритмы и априорная информация / А. Н. Тихонов [и др.]. — М. : Наука, 1983. — 200 с.
60. Речкин С. В. Цифровые технологии в организации пастбищного животноводства / Речкин С. В., Хлопко Ю. А., Огородников П. И. // Известия Оренбургского государственного аграрного университета. — 2019. — 6 (80). — С. 186—187. — URL: <https://cyberleninka.ru/article/n/tsifrovye-tehnologii-v-organizatsii-pastbischnogo-zhivotnovodstva> (дата обр. 15.10.2024) ; Number: 6 (80) Place: Россия, Оренбург Publisher: Федеральное государственное бюджетное образовательное учреждение высшего образования «Оренбургский государственный аграрный университет».
61. Рузин, С. С. Программа управления модулем системы роботизированного обнаружения сосков вымени молочной коровы с использованием ТОФ камеры / С. С. Рузин, Д. Ю. Павкин, В. В. Кирсанов. — 2021. — № 2021660863 : заявл. 12.07.2021 : опубл. 20.07.2021 : заявитель Федеральное государственное бюджетное научное учреждение «Федеральный научный агроинженерный центр ВИМ». EDN NROOKK. Свидетельство о государственной регистрации программы для ЭВМ № 2021661988 Российская Федерация.
62. Рябчиков, Д. С. Управление пассажирскими перевозками с помощью автоматизировано-информационных технологий / Д. С. Рябчиков, О. Н. Дидманидзе, А. А. Солнцев // Транспортное дело России. — 2024. — № 3. — С. 287—292. — EDN WLWQGB.
63. Сивухин Д.В. Общий курс физики. Т. 4 / Сивухин Д.В. — Физматлит, 2002.
64. Создание цифровых профилей сельскохозяйственных товаропроизводителей: Научное издание / О. А. Моторин [и др.]. — Москва : ФГБНУ «Росинформагротех», 2023. — С. 76.
65. Спектральная методика идентификации термоэлектрических элементов Пельтье на основе кусочно-линейной аппроксимации / Г. С. Васильев [и др.] // Информационные системы и технологии. — 2024. — 5(145). — С. 18—26.
66. Степанцевич, М. Н. Вопросы учёта информационной безопасности при разработке цифровых продуктов / М. Н. Степанцевич // Управление рисками в АПК. — 2024. — S3(53). — С. 324—326.

67. Технологическое развитие свиноводства и птицеводства при реализации модели экологического нормирования агропромышленного комплекса с учетом концепции наилучших доступных технологий: аналитический обзор / Т. Н. Кузьмина [и др.]. — Москва : РосНИИИТЭИ Агропрома, 2022. — 136 с. — EDN: YAZHZR.
68. Тихомиров, А. И. Организационно-экономические проблемы развития животноводства России: Монография / А. И. Тихомиров. — Дубровицы : ФГБНУ ФНЦ ВИЖ имени Л.К. Эрнеста, 2019. — 194 с.
69. Третьякова, О. Л. Оценка инновационных технологий в свиноводстве / О. Л. Третьякова, И. Ю. Свинарев, Н. А. Святогорев // Селекция и технология производства продукции животноводства: материалы международной научно-практической конференции, пос. Персиановский, 10 февраля 2021 года. — Персиановский : Донской государственный аграрный университет, 2021. — С. 98—108. — EDN: XBFQSE.
70. Трифанов, А. В. Направление совершенствования технологических решений и станков в секциях опороса свиноматок / А. В. Трифанов, В. И. Базыкин // Технологии и технические средства механизированного производства продукции растениеводства и животноводства. — 2019. — 1(98). — С. 188—195.
71. Трифанов, А. В. Обоснование размеров станочного оборудования для выращивания поросят в зависимости от роста продуктивности свиноматок / А. В. Трифанов, И. Е. Плаксин. — 2010. — URL: <https://cyberleninka.ru/article/n/obosnovanie-razmerov-stanochnogo-oborudovaniya-dlya-vyraschivaniya-porosityat-v-zavisimosti-ot-rosta-produktivnosti-svinomatok> ; АгроЭкоИнженерия. №82. Дата обращения: 10.08.2025.
72. Худякова, Е. В. Эффективность внедрения цифровых технологий в соответствии с концепцией "Сельское хозяйство 4.0" / Е. В. Худякова, М. Н. Кушнарера, М. И. Горбачев // Международный научный журнал. — 2020. — № 1. — С. 80—88.
73. Худякова, Е. В. К вопросу о методике оценки экономической эффективности внедрения цифровых инноваций в сельское хозяйство / Е. В. Худякова, М. С. Никаноров, М. Н. Степанцевич // Экономика сельского хозяйства России. — 2023. — № 2. — С. 37—44.
74. Худякова, Е. В. Организационно-экономический механизм внедрения цифровых инноваций в АПК / Е. В. Худякова, М. С. Никаноров,

- М. Н. Степанцевич // Инновационные разработки — развитию агропромышленного комплекса: Материалы юбилейной международной научно-практической конференции ФГБНУ «Северо Кавказский ФНАЦ». — Ставрополь : ООО фирма "Ставрополь-сервис-школа", 2022.
75. Худякова, Е. В. Эффективность внедрения цифровых инноваций в АПК / Е. В. Худякова, М. С. Никаноров, М. Н. Степанцевич // Известия Международной академии аграрного образования. — 2023. — № 65. — С. 99—104.
 76. Худякова, Е. В. Основные проблемы цифровой трансформации сельского хозяйства и пути их решения / Е. В. Худякова, М. Н. Степанцевич, М. И. Горбачев // Известия Международной академии аграрного образования. — 2022. — № 62. — С. 156—160.
 77. Худякова, Е. В. Проблемы и перспективы цифровой трансформации АПК / Е. В. Худякова, М. Н. Степанцевич, М. С. Никаноров // Международный журнал аграрной науки и образования. — 2024. — 1(1). — С. 132—139.
 78. Цифровая трансформация агропромышленного комплекса / Т. И. Ашмарина [и др.]. — Москва : ООО "Мегаполис", 2022. — С. 160.
 79. Цифровые двойники в цифровом профилировании сельхозпредприятий / О. А. Моторин [и др.] // Научно-информационное обеспечение инновационного развития АПК: Материалы XVI Международной научно-практической Интернет-конференции. — п. Правдинский, Московская область : Российский НИИ информации и технико-экономических исследований по инженерно-техническому обеспечению АПК, 2024. — С. 492—498.
 80. Шемякин, А. В. Автоматизация медицинского освидетельствования водителей для обеспечения безопасности перевозочных процессов / А. В. Шемякин, И. А. Успенский, О. Н. Дидманидзе // Транспортное дело России. — 2023. — № 5. — С. 110—113. — EDN TEULRH.
 81. Юшкова Л.Я. Селекционно-производственные и организационно-зоотехнические мероприятия / Юшкова Л.Я, Ким А.С // Эффективное животноводство. — 2023. — 4 (186). — С. 66—68. — URL: <https://cyberleninka.ru/article/n/seleksionno-proizvodstvennye-i-organizatsionno-zootekhnicheskie-meropriyatiya> (дата обр. 15.10.2024) ; Number: 4 (186) Place: Россия, Краснодар Publisher: Общество с ограниченной ответственностью «Институт развития сельского хозяйства».

82. Яковлев О. Б. Стрессустойчивость и продуктивность свиней / Яковлев О. Б. — 2001. — URL: <https://dissercat.com/content/stressustoichivost-i-produktivnost-svinei> (дата обр. 15.10.2024) ; Pages: 173.
83. Animal Identification / J. Bodkhe [и др.]. — 2018. — Дек.
84. Animal Identification / Jayati B. [и др.]. — 2018. — Дек.
85. Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning / Norouzzadeh M. S. [и др.]. — 2017. — Нояб. — URL: <http://arxiv.org/abs/1703.05830> (дата обр. 18.10.2024) ; arXiv:1703.05830.
86. Bishop, C. M. Training with noise is equivalent to Tikhonov regularization / C. M. Bishop // Neural Computation. — 1995. — Т. 7, № 1. — С. 108—116. — URL: <https://doi.org/10.1162/neco.1995.7.1.108>.
87. Boix-Adsera E. Towards a theory of model distillation / Boix-Adsera E. — 2024. — Май. — URL: <http://arxiv.org/abs/2403.09053> (дата обр. 18.10.2024) ; arXiv:2403.09053.
88. Chong W. Model Distillation with Knowledge Transfer from Face Classification to Alignment and Verification / Chong W., Xipeng L., Yangang Z. — 2017. — Окт. — URL: <http://arxiv.org/abs/1709.02929> (дата обр. 18.10.2024) ; arXiv:1709.02929.
89. Comprehensive Performance Evaluation of YOLO11, YOLOv10, YOLOv9 and YOLOv8 on Detecting and Counting Fruitlet in Complex Orchard Environments / Ranjan S. [и др.]. — 2024. — Окт. — URL: <http://arxiv.org/abs/2407.12040> (дата обр. 18.10.2024) ; arXiv:2407.12040.
90. Dissecting the NVidia Turing T4 GPU via Microbenchmarking / Zhe J. [и др.]. — 2019. — Март. — URL: <http://arxiv.org/abs/1903.07486> (дата обр. 18.10.2024) ; arXiv:1903.07486.
91. Dive into Deep Learning / A. Zhang [и др.] // arXiv preprint arXiv:2106.11342. — 2021. — URL: <https://d2l.ai/>.
92. Dropout: A Simple Way to Prevent Neural Networks from Overfitting / N. Srivastava [и др.] // Journal of Machine Learning Research. — 2014. — Т. 15. — С. 1929—1958. — URL: <https://jmlr.org/papers/v15/srivastava14a.html>.

93. Duan, L. Comparative Analysis of Vision-Based and Sensor-Based Animal Identification / L. Duan, X. Chen // Computers in Agriculture. — 2019. — Т. 98. — С. 47–55. — URL: <https://doi.org/10.1016/j.compag.2019.01.005> ; International source.
94. Goodfellow, I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. — MIT Press, 2016. — Гл. 7. — URL: <https://www.deeplearningbook.org/>.
95. ImageNet-21K Pretraining for the Masses / Tal R. [и др.]. — 2021. — АБГ. — URL: <http://arxiv.org/abs/2104.10972> (дата обр. 18.10.2024) ; arXiv:2104.10972.
96. Ioffe, S. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift / S. Ioffe, C. Szegedy // Proceedings of the 32nd International Conference on Machine Learning. — 2015. — С. 448–456. — URL: <https://arxiv.org/abs/1502.03167>.
97. Johnson, M. Deep Neural Networks in Precision Agriculture / M. Johnson, W. Li // Neural Networks. — 2020. — Т. 129. — С. 190–202. — URL: <https://doi.org/10.1016/j.neunet.2020.03.005> ; International source.
98. Kim, S. Robust Object Detection in Agricultural Environments Using Deep Learning / S. Kim, J. Park // Pattern Recognition Letters. — 2020. — Т. 130. — С. 158–165. — URL: <https://doi.org/10.1016/j.patrec.2020.05.007> ; International source.
99. Martinez, R. Cloud Computing and IoT in Precision Agriculture / R. Martinez, J. Lee // Future Generation Computer Systems. — 2020. — Т. 115. — С. 432–443. — URL: <https://doi.org/10.1016/j.future.2020.01.045> ; International source.
100. Microsoft COCO Captions: Data Collection and Evaluation Server / Xinlei C. [et al.]. — 2015. — Apr. — URL: <http://arxiv.org/abs/1504.00325> (visited on 10/18/2024) ; arXiv:1504.00325 [cs].
101. Morozov, V. Innovative Approaches to Livestock Health Monitoring / V. Morozov, S. Lebedev // Journal of Agricultural Innovation. — 2021. — Т. 7, № 1. — С. 55–62. — URL: <https://doi.org/10.1016/j.jai.2021.01.007> ; International source.

102. O'Connor, L. Hybrid Techniques for Robust Animal Recognition in Harsh Environments / L. O'Connor, S. Patel // Expert Systems with Applications. — 2020. — Т. 153. — С. 113—121. — URL: <https://doi.org/10.1016/j.eswa.2020.113> ; International source.
103. Olsson, D. Wireless Communication in Smart Farming Applications / D. Olsson, K. Reddy // Ad Hoc Networks. — 2020. — Т. 104. — С. 102155. — URL: <https://doi.org/10.1016/j.adhoc.2019.102155> ; International source.
104. Rossing W. Animal identification: introduction and history / Rossing W. // Computers and Electronics in Agriculture. — 1999. — Ноябрь. — Т. 24, № 1. — С. 1—4. — (Дата обр. 15.10.2024).
105. Rumelhart, D. E. Learning representations by back-propagating errors / D. E. Rumelhart, G. E. Hinton, R. J. Williams // Nature. Т. 323. — 1986. — С. 533—536. — URL: <https://doi.org/10.1038/323533a0>.
106. Sidorov, A. Econometric Analysis of Technological Innovations in Agriculture / A. Sidorov // Agricultural Economics. — 2020. — Т. 15, № 3. — С. 88—96. — URL: <https://doi.org/10.1016/j.ageco.2020.03.004> ; International source.
107. Taylor, R. Advances in Internet of Things for Animal Monitoring / R. Taylor, N. Gupta // IEEE Internet of Things Journal. — 2020. — Т. 7, № 11. — С. 10455—10463. — URL: <https://doi.org/10.1109/JIOT.2020.2994751> ; International source.
108. Tikhonov, A. N. On the solution of ill-posed problems and the method of regularization / A. N. Tikhonov // Doklady Akademii Nauk SSSR. — 1963. — Т. 151. — С. 501—504. — URL: <https://www.mathnet.ru/eng/dan/v151/i3/p501>.
109. Walker, E. Smart Farming: Technologies and Trends / E. Walker, R. Davis // Sensors. — 2021. — Т. 21, № 9. — С. 3045. — URL: <https://doi.org/10.3390/s21093045> ; International source.
110. Williams, E. Data Analytics and Predictive Modeling in Agricultural Systems / E. Williams, M. Zhao // Agricultural Systems. — 2020. — Т. 176. — С. 102720. — URL: <https://doi.org/10.1016/j.agsy.2020.102720> ; International source.

111. Williams, L. Smart Sensors and Data Analytics in Modern Agriculture / L. Williams, M. Patel // Sensors. — 2021. — Т. 21, № 11. — С. 3842. — URL: <https://doi.org/10.3390/s21113842> ; International source.
112. Wright, T. Advanced Signal Processing for Infrared Systems / T. Wright, M. Zhao // Signal Processing. — 2020. — Т. 173. — С. 107641. — URL: <https://doi.org/10.1016/j.sigpro.2020.107641> ; International source.
113. You Only Look Once: Unified, Real-Time Object Detection / Redmon J. [и др.]. — 2016. — Май. — URL: <http://arxiv.org/abs/1506.02640> (дата обр. 18.10.2024) ; arXiv:1506.02640.

Список рисунков

2.1	Сравнительная характеристика методов идентификации животных .	41
2.2	Радарная диаграмма сравнения методов идентификации	42
2.3	Пример изображения для обучения модели детекции с производства	47
2.4	Пример изображения для обучения модели детекции с производства	48
2.5	Генерация различных условий освещенности	60
2.6	Метрики процесса дистилляции модели YOLO11	61
3.1	Прототип системы. Версия 1	79
3.2	Схема метки детекции	82
3.3	Схема работы системы идентификации	83
3.4	Прототип системы: тепловизор, камера и одноплатный компьютер Raspberry Pi	85
3.5	Прототип системы: тепловизор и камера	86
3.6	Отладка системы	87
3.7	Клиентское приложение для производственных испытаний	95
4.1	Нагрузочное тестирование системы	99
4.2	Распределение систематического отклонения по условиям	101
4.3	Распределение точности идентификации по условиям	102
4.4	Стабильность работы системы в течение 24 часов	103
4.5	Сетевые сбои при различных уровнях нагрузки	104
4.6	Задержка при увеличении числа объектов	105
4.7	Влияние количества объектов на точность при использовании минимальных вычислительных мощностей	106
5.1	Время обработки одного кадра в зависимости от разрешения	109
5.2	Влияние угла камеры на точность идентификации	110
5.3	Зависимость точности от частоты кадров	111
5.4	Влияние освещённости на точность идентификации	111
5.5	Сравнение динамики окупаемости различных подходов к идентификации животных	118
A.1	Акт о внедрении результатов диссертационного исследования в ООО «Башкирская мясная компания»	146

А.2	Акт о внедрении результатов диссертационного исследования в ООО «Агромилк»	147
Б.1	Интеллектуальный сервис инфракрасной системы идентификации сельскохозяйственных животных	148
Б.2	Сервис почвенных изысканий	149
Б.3	Цифровой сервис детекции болезней яблони	150
В.1	BRICS Industrial Innovation Contest 2024	151
В.2	Студенческий стартап	152

Список таблиц

1.1	Сравнительная характеристика методов идентификации животных .	18
1.2	Направления применения ИК-идентификации в АПК	34
3.1	План проведения экспериментов	80
3.2	Параметры детектируемых объектов	92
3.3	Сводная таблица погрешностей	93
3.4	Пример результатов тестирования	94
4.1	Выдержка из мониторинга стабильности работы системы (первые 10 часов)	100
4.2	Влияние числа объектов на точность и задержку	100
4.3	Сетевые сбои при различных уровнях нагрузки	104
5.1	Первоначальные затраты на внедрение системы	115
5.2	Расчет годовой экономии	116
5.3	Пример расчета показателей экономической эффективности от интеграции системы в свиноводческих комплексах	119

Приложение А

Акты о внедрении результатов диссертационного исследования



ИНН 0214005782, КПП 021401001
 ОГРН: 1110250000508
 Юридический адрес:
 452740, Россия, Республика
 Башкортостан, Благоварский р-он,
 с. Языково, ул. Пушкина, д. 19
 Почтовый адрес:
 450001, Россия, Республика
 Башкортостан, г. Уфа, Проспект
 Октября, д. 1
 Email: uk.ufa@tavros.ru
 www.TAVROS.ru
 Тел: +7 (347) 246-44-29

Исх. № Пр-1800/351/1800
 От «06» октября 2025 г.

АКТ

о внедрении результатов диссертационного исследования

Настоящим актом подтверждается, что результаты научно-исследовательской и опытно-конструкторской работы, проведенной в рамках диссертационного исследования Абдрахимова Даниила Александровича на тему «Система идентификации сельскохозяйственных животных на основе искусственного интеллекта и инфракрасной системы детекции», внедрены в деятельность ООО «Башкирская мясная компания» и реализованы для идентификации свиней.

В результате промышленной проверки системы идентификации сельскохозяйственных животных на основе искусственного интеллекта и инфракрасной системы детекции были идентифицированы все особи, а также их перемещения, результаты были успешно собраны в базу данных. Применение данного передового решения, основанного на технологиях искусственного интеллекта, демонстрирует высокую эффективность. Система идентификации сельскохозяйственных животных позволяет повысить эффективность процессов, связанных с отслеживанием физиологического и поведенческого статуса животных. Система обладает значительным потенциалом для масштабирования.

Генеральный директор



А.Т. Мустафин

Рисунок А.1 — Акт о внедрении результатов диссертационного исследования в
 ООО «Башкирская мясная компания»



ООО «АГРОМИЛК»
162620, Вологодская область, г. Череповец, ул. Центральная, д.12
ИНН 7733758246, КПП 352801001, ОГРН 1117746089009
тел./факс (8202)63-30-17
эл. почта agromilk35@mail.ru

23.05.2025 № 04/23-27

АКТ
о внедрении результатов
диссертационного исследования

Настоящим актом удостоверяется, что результаты научно-исследовательской и опытно-конструкторской работы, выполненной в рамках диссертационного исследования Абдрахимова Даниила Александровича на тему «Система идентификации сельскохозяйственных животных с использованием искусственного интеллекта и инфракрасных детекторов», успешно внедрены в деятельность ООО «Агромилк». Данная система применялась для идентификации крупного рогатого скота.

В процессе промышленной проверки системы идентификации сельскохозяйственных животных, основанной на искусственном интеллекте и инфракрасных детекторах, были успешно идентифицированы все особи крупного рогатого скота и зафиксировано их движение. Внедрение системы идентификации сельскохозяйственных животных представляет собой инновационную технологию, направленную на повышение эффективности процессов мониторинга состояния животных. Эта система обеспечивает более точное и оперативное получение данных, необходимых для принятия обоснованных управленческих решений.





С.Н. Блюма

Рисунок А.2 — Акт о внедрении результатов диссертационного исследования в
ООО «Агромилк»

Приложение Б

Результаты интеллектуальной деятельности



Рисунок Б.1 — Интеллектуальный сервис инфракрасной системы идентификации сельскохозяйственных животных

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2024686455

«Сервис почвенных изысканий»

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет - МСХА имени К.А. Тимирязева» (RU)*

Авторы: *Борисов Борис Анорьевич (RU), Ефимов Олег Евгеньевич (RU), Минаев Николай Викторович (RU), Степанцевич Марина Николаевна (RU), Абдрахимов Даниил Александрович (RU), Лапушкина Анастасия Андреевна (RU), Бородина Кира Сергеевна (RU)*

Заявка № 2024684704

Дата поступления 22 октября 2024 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 08 ноября 2024 г.



Руководитель Федеральной службы
по интеллектуальной собственности

Ю.С. Зубов

Рисунок Б.2 — Сервис почвенных изысканий

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2024689009

«Цифровой сервис детекции болезней яблони»

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет - МСХА имени К.А. Тимирязева» (RU)*

Авторы: *Касатов Илья Сергеевич (RU), Степанцевич Марина Николаевна (RU), Абдрахимов Даниил Александрович (RU)*



Заявка № **2024687750**

Дата поступления **18 ноября 2024 г.**

Дата государственной регистрации

в Реестре программ для ЭВМ **03 декабря 2024 г.**

Руководитель Федеральной службы
по интеллектуальной собственности

Ю.С. Зубов

Рисунок Б.3 — Цифровой сервис детекции болезней яблони

Приложение В

Дипломы



Рисунок В.1 — BRICS Industrial Innovation Contest 2024



Рисунок В.2 — Студенческий стартап