

**ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«РОССИЙСКИЙ БИОТЕХНОЛОГИЧЕСКИЙ УНИВЕРСИТЕТ»**

На правах рукописи



СОХИНОВ ДМИТРИЙ ЮРЬЕВИЧ

**СОВЕРШЕНСТВОВАНИЕ ПРОЦЕССА
АВТОМАТИЗИРОВАННОЙ СОРТИРОВКИ ЯБЛОК
ПРИМЕНЕНИЕМ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ**

Специальность 2.3.3 –

Автоматизация и управление технологическими процессами и
производствами

Диссертация

на соискание ученой степени кандидата технических наук

Научный руководитель,
доктор технических наук, доцент
Каргин Виталий Александрович

Москва – 2025

ОГЛАВЛЕНИЕ

Введение.....	5
1. СПОСОБЫ И ТЕХНИЧЕСКИЕ СРЕДСТВА ОЦЕНКИ КАЧЕСТВА ЯБЛОК. ПОСТАНОВКА ЦЕЛИ И ЗАДАЧ ИССЛЕДОВАНИЯ.....	13
1.1 Перспективы развития плодоовощной продукции в России.....	13
1.2. Технологии производства яблочного сока.....	15
1.3 Классификация повреждений плодов.....	18
1.3.1 Механические повреждения.....	19
1.3.2 Биологические повреждения.....	19
1.3.3 Физиологические повреждения.....	21
1.4 Методы и технические средства оценки качества яблок.....	23
1.4.1 Метод на основе применения цветных телевизионных датчиков.....	23
1.4.2 Метод на основе гиперспектрального анализа.....	25
1.4.3 Электрические и оптические методы контроля качества.....	27
1.4.4 Оптический метод на основе флуоресценции хлорофилла.....	29
1.5 Системы технического зрения для распознавания дефектов плодов.....	30
1.6 Цель и задачи исследования.....	36
1.7 Выводы по первой главе.....	36
2. ТЕОРЕТИЧЕСКИЕ ПРЕДПОСЫЛКИ РЕАЛИЗАЦИИ АЛГОРИТМА КОСВЕННОЙ ОЦЕНКИ КАЧЕСТВА ПЛОДОВ ПРИ АВТОМАТИЗИРОВАННОЙ СОРТИРОВКЕ	38
2.1 Постановка задач.....	38
2.2 Разработка обобщенной схемы алгоритма управления автоматизированной сортировкой.....	39
2.3 Разработка алгоритма косвенной оценки объема повреждения плодов....	42
2.3.1 Математическая модель зависимости объема повреждения плода от площади дефекта.....	42
2.3.2 Разработка и визуализация алгоритма косвенной оценки объема повреждения плодов.....	46

2.4 Математическое моделирование неопределенности и пограничных состояний плодов в нечеткой логике с приоритетной иерархией решений....	48
2.4.1 Агрегация и верификация результатов.....	48
2.4.2 Возможности нечеткой логики в моделировании степени повреждения плодов.....	49
2.4.3 Выбор лингвистических переменных и построение базы правил.....	52
2.4.4 Реализация иерархической структуры логического вывода.....	61
2.5 Выводы по второй главе.....	67
3. ПРОГРАММНАЯ РЕАЛИЗАЦИЯ ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ СОРТИРОВКИ ПЛОДОВ.....	69
3.1 Постановка задач.....	69
3.2 Реализация подзадач алгоритма автоматизированной сортировки яблок.....	70
3.2.1 Инициализация аппаратной платформы.....	71
3.2.2 Захват и сохранение изображений плодов.....	72
3.2.3 Передача данных в модуль предобработки.....	74
3.2.4 Проверка качества входных данных.....	76
3.2.5 Коррекция и фильтрация изображения.....	77
3.2.6 Нормализация цвета и выделение контуров плода.....	79
3.2.7 Формирование набора предобработанных изображений.....	81
3.2.8 Инициализация и загрузка сверточной нейронной сети.....	82
3.2.9 Выделение области повреждения.....	84
3.2.10 Подзадачи «Определения площади и объема повреждения плодов» и «Агрегации и верификации результатов».....	85
3.2.11 Сохранение в базе данных.....	87
3.2.12 Формирование выходных отчетов и визуализация данных.....	88
3.3 Модель сверточной нейронной сети для оценки повреждения плодов.....	90
3.3.1 Сбор и разметка данных для обучения модели.....	90
3.3.2 Выбор и обоснование модели СНС для задачи оценки повреждений плодов.....	93
3.3.3 Обучение модели <i>YOLOv11-seg</i>	98

3.3.4 Результаты обучения модели.....	100
3.4 Реализация системы отслеживания и сохранения объектов из видеопотока.....	105
3.5 Реализация алгоритма оценки объема повреждения плода при помощи системы компьютерного зрения.....	109
3.5.1 Основной цикл определения повреждения плода.....	109
3.5.2 Функция расчета объема и радиуса плода.....	112
3.5.3 Программная реализация нечеткой системы принятия решений для оценки качества яблок.....	114
3.6 Реализация управления ПЛК.....	117
3.7 Выводы по третьей главе.....	121
4. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ СОРТИРОВКИ ПЛОДОВ.....	123
4.1 Физическая модель и методика экспериментальных исследований.....	123
4.1.1 Технические средства эксперимента.....	124
4.1.2 Методика проведения экспериментальных исследований.....	126
4.2 Применение метода теории планирования многофакторного эксперимента к исследованию системы сортировки.....	130
4.2.1 Применение многофакторного эксперимента.....	130
4.2.2 Построение регрессионной модели $Loss=f(h,v,\alpha)$	133
4.3 Оценка производительности линии сортировки.....	139
4.4 Выводы по четвертой главе.....	143
Общие выводы.....	145
Список литературы.....	147
ПРИЛОЖЕНИЯ.....	169

Введение

Плодоовощная продукция традиционно занимает важное место в структуре пищевого и агропромышленного комплекса Российской Федерации. В стране выращивается широкий спектр овощей и фруктов, которые поступают как на рынок в свежем виде, так и в переработку. В частности, наиболее динамично развивающимся сегментом среди направлений переработки, производство соков занимает особое место. При этом обширные площади яблоневых садов, расположенные в различных климатических зонах страны, а также высокий спрос на натуральные продукты питания формируют базу для выпуска яблочных соков.

Повышение спроса на натуральные продукты и расширение ассортимента перерабатываемого сырья требуют постоянного совершенствования технологий, направленных не только на улучшение органолептических характеристик конечного продукта, но и на повышение его микробиологической стабильности. Ключевым фактором, определяющим качество сока, остаётся состояние исходного сырья – плодов, поступающих на переработку. Механические повреждения, ушибы или царапины, которые не влияют на внутреннюю структуру яблока, не являются критичными для процесса. Тогда как, даже небольшое поражение гнилью приводит к ухудшению вкусовых и химических свойств сока, что снижает его качество и срок хранения.

Автоматизированная сортировка плодов является важнейшим элементом современных производственных линий в пищевом и агропромышленном комплексе. Однако в малом и среднем секторе операции по отбору плодов зачастую выполняются вручную.

Таким образом создание автоматизированной системы сортировки, которая будет игнорировать незначительные внешние дефекты и предсказывать объём гнили по площади повреждения плода, является важной задачей.

Современные методы оценки качества плодов, основанные, например, на гиперспектральном анализе или флуоресценции, имеют сложную калибровку и высокую вычислительную нагрузку; или использующие системы технического

зрения (СТЗ), из-за чрезмерной чувствительности только к внешним дефектам приводят к неоправданной отбраковке, что увеличивает потери сырья и снижает эффективность переработки. Все это ограничивает их практическое применение в условиях массового производства.

Наиболее перспективным направлением здесь является интеграция алгоритмов глубокого обучения, в частности сверточных нейронных сетей (СНС), с системами нечёткой логики. Такой подход позволяет, с одной стороны, повысить точность сегментации дефектных участков, а с другой – учитывать сложные и пограничные состояния плодов, формируя гибкую и адаптивную систему оценки их пригодности к различным направлениям переработки: производство сока, пюре, кормовых продуктов или выбраковка.

В то же время внедрение подобных интеллектуальных систем требует научно обоснованного подхода к построению алгоритмов косвенной оценки объёма повреждений, разработке архитектуры логического вывода и учёта технологических ограничений линии переработки. Помимо алгоритмических задач, ключевыми аспектами являются вопросы интеграции программного обеспечения с промышленными системами автоматизации, обеспечение высокой пропускной способности при минимальной задержке и верификация результатов на реальных производственных потоках. Таким образом, решение проблемы повышения эффективности технологического процесса автоматизированной сортировки плодов применением интеллектуальной системы оценки их качества является актуальным.

Основанием для данной работы, представляющей продолжением комплекса работ по созданию и совершенствованию автоматизированных систем управления технологическими процессами, являются программы:

- Указ Президента РФ от 10 октября 2019 г. N 490 "О развитии искусственного интеллекта в Российской Федерации";
- Постановление Правительства РФ от 29 марта 2019 г. № 377 «Об утверждении государственной программы Российской Федерации

- "Научно-технологическое развитие Российской Федерации" (В редакции постановлений Правительства Российской Федерации от 15.05.2025 №656)
- Доктрина продовольственной безопасности РФ (утв. Президентом РФ, Указ №20 от 21.01.2020);

Степень разработанности темы. Исследованиями в области разработки автоматизированных систем управления занимались и занимаются Благовещенская М.М., Краснов А.Е., Злобин Л.А., Каргин В.А., Благовещенский И.Г., Мокрушин С.А., Бородин И.Ф., Судник Ю.А., Петров И.К., Андреев С.А., Аристова Н.И. и др.; разработка и применение методов и технических средств оценки качества плодоовощной продукции, а также создание алгоритмов для систем технического зрения является тематикой научных исследований ученых Жирковой А.А., Балабанова П.В., Яблокова С.А., Родикова С.А., Гурьянова Д.В., Дивина А.Г., Бласцо Й., Алеихос Н., Молто Е., Дилек Е., Денер М. и др.

Приоритетные направления в исследованиях большинства ученых связаны с разработкой и повышением эффективности собственно автоматизированных систем управления технологическими процессами, а также систем технического зрения, к том числе, в пищевой промышленности и АПК. При этом использование комплексного подхода для интеллектуальной оценки качества яблок по данным системы технического зрения и принятия решений в автоматизированной системе сортировки с применением нейросетевых алгоритмов и модели нечёткой логики в настоящее время требуют пристального внимания, совершенствования и представляют большой научно-практический интерес.

Цель работы. Разработка и научное обоснование методов повышения эффективности процесса автоматизированной сортировки плодов применением интеллектуальной системы.

Для достижения поставленной цели необходимо решить следующие задачи:

- разработать математическую модель, связывающую предполагаемый объем повреждения плода гнилью с площадью поверхности дефекта;
- разработать модель нечеткой логики с приоритетной иерархией принятия решений для классификации яблок по категориям качества;
- разработать алгоритмическое обеспечение и программную реализацию системы автоматизированной оценки качества плодов при сортировке;
- разработать методику и экспериментальную модель автоматизированной системы сортировки яблок с использованием системы технического зрения;
- теоретически и экспериментально с использованием теории планирования многофакторного эксперимента оценить влияние наиболее значимых факторов на выходные показатели автоматизированной системы сортировки – ошибку классификации и производительность.

Объект исследования – автоматизированная система сортировки яблок.

Предмет исследования – процессы интеллектуальной оценки качества яблок по данным системы технического зрения и принятия решений в автоматизированной системе сортировки с применением нейросетевых алгоритмов и модели нечёткой логики.

Научная новизна работы:

- предложена математическая модель, связывающая площадь повреждения плода с его объемом на основе аппроксимации формы плода сферой, а области повреждения – средним между полусферой и сектором, учитывающая эмпирические данные распространения гнили внутри плода, позволяющая косвенно оценивать объем повреждения на основе данных, полученных системой технического зрения;
- разработан алгоритм косвенной оценки объема повреждения плодов на основе системы нечеткой логики, в которой реализована приоритетная иерархическая структура правил принятия решений, позволяющая повысить точность классификации яблок по категориям качества;

- предложен и реализован комплексный алгоритм автоматизированной сортировки яблок, включающий, в том числе, сегментацию с использованием сверточной нейронной сети, отслеживание объектов в видеопотоке, оценку площади и объема повреждения, а также управление исполнительными механизмами на базе программируемого логического контроллера;
- предложена и экспериментально обоснована математическая модель, описывающая взаимосвязь между наиболее значимыми факторами системы технического зрения и параметрами эффективности сортировки плодов, что позволяет количественно оценить их влияние и разработать методы оптимизации процесса сортировки с учетом взаимоисключающих требований к точности и производительности.

Теоретическая и практическая значимость работы заключается:

- в разработке математической модели, связывающей площадь повреждения плода с его объемом;
- в разработке интеллектуальной системы автоматизированной сортировки яблок;
- в разработке алгоритма косвенной оценки объема повреждения плодов на основе системы нечеткой логики;
- в реализации комплексного алгоритма автоматизированной сортировки яблок;
- в обосновании математической модели описывающей взаимосвязь между наиболее значимыми факторами системы технического зрения;
- в применении результатов исследований в учебном процессе образовательных заведений при чтении лекций, проведении лабораторных и практических занятий.

Методология и методы исследований. В работе использованы комплексные методы теоретического и экспериментального исследования, включающие разработку математических моделей процессов оценки качества

плодов, методы машинного обучения на базе сверточных нейронных сетей, алгоритмы технического зрения и нечёткой логики, а также методы математического моделирования и теории планирования многофакторного эксперимента для анализа влияния технологических параметров на эффективность сортировки. При разработке и верификации алгоритмов применялись современные программные средства, а также физическая модель сортировочной линии с системой технического зрения и промышленными исполнительными механизмами.

Экспериментальные исследования проводились в лабораторных условиях с использованием современной измерительной аппаратуры, полученные данные обрабатывались методами математической статистики, а результаты, полученные графическим способом. Применительно к задачам созданы экспериментальные стенды для лабораторных исследований физической модели автоматизированной сортировки плодов.

Диссертация соответствует паспорту специальности 2.3.3 – Автоматизация и управление технологическими процессами и производствами в части пунктов 3, 5 и 6.

Научные положения и результаты исследований, выносимые на защиту:

- математическая модель, устанавливающая зависимость между площадью повреждения поверхности яблока и предполагаемым объемом внутреннего поражения плода;
- модель нечёткой логики с приоритетной иерархией правил для классификации яблок по категориям качества;
- алгоритмическое и программное обеспечение системы автоматизированной сортировки плодов на основе данных системы технического зрения;
- математическая модель зависимости показателей эффективности системы сортировки от технологических факторов, полученная с использованием теории планирования многофакторного эксперимента.

Личный вклад соискателя состоит в разработке плана исследований; проведении анализа литературных источников по обоснованию актуальности изучаемой проблемы; постановке и решении задач исследования; выполнении теоретических исследований; проведении лабораторных испытаний; разработке алгоритмического обеспечения и разработке программной реализации автоматизированной системы сортировки яблок; проведении лабораторных испытаний и на производстве; апробации результатов; подготовке и публикации научных статей по тематике работы.

Степень достоверности и апробация результатов. Достоверность результатов исследований обеспечена применением высокоточной измерительной аппаратуры и приборов, стандартных методик исследований, обработкой экспериментальных данных методами математической статистики, сходимостью результатов теоретического и экспериментального исследований, их подтверждением при практической реализации разработок в лабораторных условиях.

Технические возможности и эффективность автоматизированной сортировки плодов с использованием интеллектуальной системы признаны важными и внедрены в производство в ООО «Русь» (г. Энгельс, Саратовская область); К(Ф)Х «Хамзат» (Шалинский район, Чеченская Республика); ООО «Агрос» (Турковский район, Саратовская область). Результаты исследования используются в учебном процессе ФГБОУ ВО «РОСБИОТЕХ» при обучении бакалавриата и магистратуры.

Основные научные положения, результаты исследований, выводы и практические рекомендации диссертации были доложены, обсуждены и одобрены на:

- Всероссийская научно-практическая конференция «Интеллектуальные автоматизированные управляющие системы в биотехнологических процессах» (Москва, 2023);

- II и IV Всероссийские научно-практические конференции молодых учёных «Информатизация и автоматизация в пищевой промышленности» (Москва, 2023, 2025);
- IV, V и VI Международные конференции «Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям и роботизированным системам для отраслей пищевой промышленности» (Москва, 2023, 2024, 2025);
- Научно-практическая конференция с международным участием «Современные проблемы автоматизации технологических процессов и производств» (Москва, 2023);
- Научно-практическая конференция с международным участием «Роговские чтения» (Москва, 2023);
- Всероссийская конференция с международным участием «Автоматизированные системы управления биотехнологическими процессами» (Москва, 2024).

По теме диссертационной работы опубликовано 24 научные работы, включая 3 статьи в изданиях, входящих в Перечень рецензируемых научных изданий, рекомендованных ВАК.

Структура и объем диссертации. Диссертация состоит из введения, четырёх глав, общих выводов, списка литературы (172 наименований) и приложений. Работа изложена на 189 страницах машинописного текста, содержит 68 рисунков, 6 таблиц и 10 приложений.

1. СПОСОБЫ И ТЕХНИЧЕСКИЕ СРЕДСТВА ОЦЕНКИ КАЧЕСТВА ЯБЛОК. ПОСТАНОВКА ЦЕЛИ И ЗАДАЧ ИССЛЕДОВАНИЯ

1.1 Перспективы развития плодоовощной продукции в России

Плодоовощная продукция традиционно занимает важное место в структуре пищевого и агропромышленного комплекса России. В стране выращивается широкий спектр овощей и фруктов, которые поступают как на рынок в свежем виде, так и в переработку. Среди направлений переработки именно производство соков выделяется как наиболее динамично развивающийся сегмент, отражающий одновременно производственный потенциал и потребительские предпочтения. Особое значение в этой сфере имеет производство яблочного сока, обширные площади яблоневых садов, расположенные в различных климатических зонах страны, формируют базу для выпуска широкого ассортимента продукции. Спрос на яблочный сок, обусловленный его пищевой ценностью и натуральностью, демонстрирует устойчивый рост (рис. 1.1).




Рис. 1.1. Структура потребления соков в России

Согласно статистике последних лет, ежегодно наблюдается рост потребления сока на душу населения, что делает рынок сока одним из перспективных направлений в пищевой промышленности страны (рис. 1.2). Этому способствует ряд факторов:

- увеличение площадей яблоневых садов;
- развитие технологий переработки яблок, направленных на сохранение полезных веществ и улучшения вкусовых характеристик сока;
- рост потребительского спроса на натуральные и экологически чистые продукты питания.




Рис. 1.2. Динамика внутреннего производства и импорта яблочного сока в России

Развитие технологий переработки яблок в сок является важным элементом повышения конкурентоспособности российского яблочного сока как на внутреннем, так и на внешнем рынке. Современные технологии, такие как автоматизированные системы сортировки, ультрафильтрация и пастеризация с минимальным воздействием на продукт, позволяют сохранить максимальное количество полезных веществ в соке, а также улучшить его вкусовые характеристики. Введение на предприятиях новых технологий,

основанных на интеллектуальных системах анализа качества сырья, позволит значительно улучшить производственные процессы [1, 3, 4].

Автоматизация на всех этапах переработки позволяет не только повысить качество конечного продукта, но и сократить затраты на производство.

1.2 Технология производства яблочного сока

Процесс производства яблочного сока включает ряд последовательных этапов сбор урожая и его доставка на предприятие, подготовку сырья, измельчения и прессование, фильтрацию, пастеризацию и упаковку (рис. 1.3).




Рис. 1.3. Структурная схема технологической линии по производству яблочного сока: I этап – сбор урожая и доставка на предприятие; II этап – мойка и подготовка плодов; III этап – сортировка и отбор плодов; IV этап – измельчение и прессование; V этап – фильтрация и осветление сока; VI этап – пастеризация; VII этап – упаковка

Доставка сырья на предприятие (I этап) осуществляется непосредственно с места сбора урожая либо с фруктохранилищ. После приемки плодов следующим этапом является мойка и подготовка к дальнейшей переработке (II этап).

Основная цель мойки заключается в удалении любых загрязнений с поверхности плодов, которые могут негативно повлиять на вкус и

безопасность сока. На этом этапе удаляются все типы внешних загрязнений, включая пыль, частицы почвы, следы агрохимикатов и микроорганизмы, способные нарушить вкусовой профиль сока или сократить срок его хранения. В условиях поточного производства тщательная мойка служит не только средством обеспечения пищевой безопасности, но и важным элементом подготовки яблок к механической переработке [65, 68].

Ключевым этапом, определяющим качество и безопасность конечного продукта, является сортировка и отбор плодов (III этап). Здесь необходимо отделить яблоки, соответствующие требованиям к сырью, от плодов, содержащих биологические, физиологические и другие повреждения, а также неудовлетворяющих по зрелости, сорту и тд.

На сегодняшний день сортировка яблок выполняется вручную, особенно на малых и средних предприятиях, где производственные объёмы не позволяют внедрить дорогостоящее оборудование (рис 1.4). Ручная сортировка основана на визуальной оценке состояния плодов, в ходе которой работники отбирают пригодные для переработки яблоки и удаляют дефектные. Однако такой подход имеет ряд ограничений в том числе, субъективность оценки, низкая скорость обработки и высокие трудозатраты.



Рис. 1.4. Ручная сортировка плодов на производстве яблочного сока

На IV этапе производится измельчение и прессования яблок с целью извлечения максимального количества сока. Оптимальная степень измельчения позволяет максимально раскрыть клеточные структуры плодов, обеспечивая выделение сока и сохранение его вкусовых характеристик.

Прессование яблочной мякоти – это этап, на котором происходит физическое отделение сока от жмыха. В технологической практике современных перерабатывающих предприятий используется несколько типов прессового оборудования, каждый из которых решает задачи извлечения сока с разной степенью эффективности и влияния на качество продукта. Традиционным и проверенным вариантом остаются гидравлические прессы, создающие стабильное и равномерное давление на мякоть [9, 11].

Фильтрация и осветление сока (V этап) являются этапами в производстве, которые направлены на улучшение вкуса, текстуры и внешнего вида продукта. Эти процессы обеспечивают удаление мелких частиц и взвешенных веществ, которые могли остаться после прессования, и позволяют получить прозрачный сок, соответствующий требованиям потребителей. Особенно важным этот этап становится при производстве осветленного яблочного сока, который пользуется широкой популярностью на рынке.

Данный этап проводится сразу после прессования и направлена на удаление механических примесей и крупных частиц, таких как фрагменты кожуры, мякоти и косточек.

Фильтрация является важнейшим этапом в производстве яблочного сока, направленным на удаление механических примесей и обеспечение стабильной текстуры напитка при сохранении его природных свойств. Одним из наиболее прогрессивных методов считается мембранная фильтрация, при которой сок пропускается через полупроницаемые барьеры, способные задерживать частицы определённого размера. Это позволяет эффективно отделить нежелательные включения, не затрагивая при этом ароматические и питательные компоненты.

Завершающими этапами (VI и VII этапы) производства сока является пастеризация и упаковка, которые обеспечивают безопасное длительное хранение конечного продукта. Эти процессы направлены на уничтожение микроорганизмов и предотвращение окисления сока, а также на создание условий для его транспортировки и потребления. От правильной пастеризации и качественной упаковки зависят срок годности и сохранение вкусовых качеств сока.

Анализ технологического оборудования для производства яблочного сока показал, что в целом используемые технические средства позволяют решать задачи извлечения сока с разной степенью эффективности, требуемой производительностью и уровнем автоматизации [92].

Однако ручной труд на этапе сортировки затрудняет обработку больших объёмов продукции в период пикового сбора урожая. Высокие затраты на оплату труда и утомляемость работников становятся факторами, ограничивающими производительность и стабильность качества [33, 34].

Кроме того, ручной труд не позволяет эффективно выявлять внутренние дефекты, такие как гниль, что негативно сказывается на качестве готового продукта. Внедрение автоматизированных систем с расширенными возможностями, такими как анализ внутренних структур плодов, стало бы важным шагом на пути к повышению стабильности и безопасности продукции.

1.3 Классификация повреждений плодов

При переработке яблок в сок важно учитывать не только сорт и зрелость плодов, но и наличие различных повреждений. Эти дефекты могут значительно влиять на качество готового продукта, сокращая срок хранения и ухудшая вкусовые характеристики. Различают три основных типа повреждений: механические, биологические и физиологические. Их следует выявлять на ранних этапах переработки, однако это часто вызывает трудности, особенно при обнаружении скрытых дефектов.

1.3.1 Механические повреждения

Механические повреждения являются распространённым типом дефектов, возникающих при сборе, транспортировке и хранении яблок. Они негативно влияют на качество плодов и делают их менее пригодными для переработки в сок. Повреждённые яблоки подвержены ускоренному окислению и могут стать очагами заражения грибковыми инфекциями.

Наиболее распространённые механические дефекты включают вмятины, образующиеся при неаккуратной погрузке или падении плодов; трещины и разрывы кожицы, возникающие в результате ударов или перегрузки при транспортировке; а также проколы и царапины, нередко появляющиеся в процессе ручной или автоматической сортировки. Все эти повреждения не только ухудшают внешний вид яблока, но и снижают его технологическую пригодность, увеличивая вероятность порчи и потерь сырья в процессе переработки.

1.3.2 Биологические повреждения

Биологические повреждения яблок связаны с активным развитием различных грибковых заболеваний, которые могут поражать плоды как в процессе их роста, так и во время хранения. Эти повреждения приводят к потере урожая, ухудшению вкуса и цвета продукта, сокращению срока хранения сока и даже могут представлять угрозу для здоровья потребителей. Одной из основных сложностей является тот факт, что многие заболевания развиваются скрытно, и их невозможно заметить на ранних стадиях. Повреждённые плоды не только ухудшают органолептические свойства сока, но и создают условия для роста патогенных микроорганизмов, что может стать причиной микробиологической порчи продукта.

Одной форм скрытых повреждений, особенно опасной для переработки в сок, является горькая гниль (рис. 1.5, а), вызванная грибами рода *Gleosporium*, а также серая гниль (рис 1.5, б), вызываемая грибом *Botrytis*

cinerea, которые способны поражать яблоки как в период вегетации, так и уже после сбора – на стадии хранения.



Рис. 1.5. Плоды, поврежденные горькой гнилью (а) и серой гнилью (б)

При хранении такие плоды становятся очагом распространения инфекции, резко ускоряя процессы порчи и приводя к массовым потерям урожая. Более того, в процессе переработки они способны выделять ферменты и продукты распада, негативно влияющие на вкус, цвет и микробиологическую стабильность сока. Даже незначительное количество

таких плодов в партии способно снизить срок хранения готового продукта и сделать его уязвимым к вторичной ферментации. Именно поэтому надёжная идентификация и изоляция плодов с серой гнилью является обязательным условием устойчивой технологии переработки.

Монилиоз, вызываемый грибом *Monilinia fructigena*, представляет собой одну из наиболее опасных форм плодовой гнили, поражающую яблоки как в саду, так и при хранении.

Не менее разрушительным, особенно при нарушении условий хранения, является развитие мягкой гнили, вызываемой грибами родов *Mucor* и *Rhizopus*. Эта форма заболевания развивается стремительно: яблоки становятся мягкими, водянистыми и теряют структурную целостность. Даже единичные инфицированные плоды способны в кратчайшие сроки испортить значительный объём урожая. При попадании в переработку они резко ухудшают органолептику сока, повышают кислотность и уровень микробной активности, что приводит к нестабильности продукта и его быстрому брожению.

1.3.3 Физиологические повреждения

Физиологические повреждения яблок возникают не вследствие патогенов или механических воздействий, а как следствие неблагоприятных условий выращивания и хранения. Дефицит влаги, повышенные температуры, нестабильный микроклимат в камерах хранения – все эти факторы способны инициировать изменения, которые долгое время остаются незаметными, но критически влияют на внутреннюю структуру и химический состав плодов. Особенно опасны такие повреждения в контексте переработки в сок, где даже единичные испорченные плоды могут нарушить вкусовой профиль и микробиологическую стабильность готового продукта.

Одним из наиболее часто встречающихся физиологических нарушений является горькая ямчатость (рис. 1.6, а). Она проявляется в виде точечных пятен диаметром порядка 3 мм, изначально зелёных, но со временем

приобретающих бурый или даже чёрно-красный оттенок. Ткань в этих участках становится губчатой и деградирует по текстуре, а вкус яблока теряет характерную сочность.



а)



б)

Рис. 1.6. Пример физиологических повреждений яблок: горькая ямчатость (а) и распад мякоти (б)

Распад мякоти (рис. 1.6, б) – ещё одна опасная форма физиологического ухудшения качества. Этот процесс сопровождается деградацией клеточных стенок, потерей упругости и появлением мучнистой консистенции. Кожица таких яблок зачастую отслаивается буквально от лёгкого прикосновения. Особенно сильно подвержены распаду крупные плоды, выращенные на

молодых деревьях, в которых нарушен баланс между ростом и физиологическим созреванием. При переработке такие фрукты дают нестабильный по кислотности и вкусу сок, склонный к расслаиванию и порче.

1.4 Методы и технические средства оценки качества яблок

Автоматизация сортировки плодов является важнейшим элементом современных производственных линий в пищевом и агропромышленном комплексе. В частности, при переработке яблок для производства сока возникает необходимость точного выявления дефектов, которые могут существенно повлиять на качество конечного продукта. Среди различных дефектов яблок, таких как механические повреждения, пятна, и царапины, наиболее критичным является наличие гнили. Пораженные гнилью яблоки могут привести к ухудшению вкусовых и химических свойств сока, что снижает его качество и срок хранения [149, 151].

Особенность задачи заключается в том, что не все дефекты яблок оказывают негативное влияние на переработку в сок. Механические повреждения, ушибы или царапины, которые не влияют на внутреннюю структуру яблока, не являются критичными для процесса. Тогда как, даже небольшое поражение гнилью внутри плода может существенно повлиять на качество конечного продукта. Таким образом создание автоматизированной системы сортировки, которая будет игнорировать незначительные внешние дефекты и точно определять наличие и объём гнили, является актуальной задачей [19, 26, 27].

Рассмотрим существующие методы и технические средства для оценки качества плодов.

1.4.1 Метод на основе применения цветных телевизионных датчиков

Метод, предложенный Д.В. Гурьяновым, представляет собой решение, ориентированное на автоматизированную сортировку яблок на основе анализа

их внешней поверхности с использованием цветowych телевизионных датчиков. В своей основе он опирается на обработку полноцветных изображений, полученных в системе RGB, и позволяет выявлять поверхностные дефекты, такие как пятна, вмятины, механические проколы и визуально различимые признаки заболеваний. Целью подхода является оперативная сортировка продукции в потоке по категориям качества, исходя из визуальных параметров кожуры плода [72].

Техническая реализация метода (рис. 1.7) базируется на архитектуре, включающей надконвейерные видеокамеры, осветители и программный модуль анализа. Яблоки, перемещающиеся по транспортной ленте, фиксируются в процессе движения с нескольких ракурсов. Для получения максимально полной информации о поверхности каждый плод подвергается вращению, что обеспечивает круговой охват. Далее программный блок выполняет цветовую сегментацию изображений: каждый пиксель анализируется с точки зрения его цветовых координат, которые сопоставляются с эталонными значениями для данного сорта яблок. Нарушения однородности цвета или появления характерных оттенков служат индикатором возможных повреждений [76, 77].




Рис. 1.7. Схема стенда для исследования полноцветных изображений поверхности продукции: 1-корпус; 2-подставка; 3- осветители; 4-видеокамера; 5 - компьютер; 6- программное обеспечение; 7-исследуемый плод; 8-пятно повреждения.

Особенность реализации метода заключается в использовании имитационной модели, предварительно обученной на массиве изображений яблок с различными типами дефектов. В её основе лежат данные о спектре цветовых отклонений для каждой формы повреждения. Для анализа применяется линейная нейросетевая архитектура, ориентированная на быструю и масштабируемую обработку данных [73, 74, 75].

Однако чрезмерная чувствительность системы к малозначимым дефектам, таким как мелкие царапины или поверхностные потёртости, не оказывающие влияния на химико-биологические свойства плода и, следовательно, не критичные для переработки в сок, приводит к избыточной отбраковке, увеличению потерь сырья и неоправданным технологическим издержкам. Метод не учитывает метаболическую составляющую состояния плодов, ограничиваясь исключительно геометрическими и цветовыми признаками, что ограничивает его использование в системах сортировки, ориентированных на продукцию для глубокой переработки.

1.4.2 Метод на основе гиперспектрального анализа

Метод, разработанный Александрой Александровной Жирковой, представляет собой высокотехнологичный подход к оценке качества яблок, в основе которого лежит гиперспектральный анализ отражательного спектра поверхности плодов. Его ключевое отличие от традиционных систем видеоконтроля заключается в ширине регистрируемого спектра: вместо трёх цветовых каналов RGB используется непрерывный диапазон длин волн от 400 до 1000 нм. Это позволяет получить обогащённое изображение, несущие в себе информацию не только о внешнем цвете, но и о структурных и физиологических изменениях тканей, зачастую недоступных для обычного визуального наблюдения [81].

В техническом плане метод реализуется с помощью специализированной информационно-измерительной системы (рис. 1.8), включающей гиперспектральную камеру, блок сканирования, персональный

компьютер с программным обеспечением, модуль управления и механизм отбраковки. При прохождении яблока по конвейерной ленте камера формирует гиперспектральный куб изображений – трёхмерный массив данных, где двум пространственным координатам добавлена спектральная ось. Это позволяет фиксировать отклики тканей плода в десятках и сотнях узких диапазонов длины волны, формируя комплексный портрет отражательных свойств объекта [78, 82].




Рис. 1.8. Функциональная схема информационно-измерительной системы контроля качества яблок и макета для их сортировки: 1-конвейер; 2-плоды; 3-камера; 4-система гиперспектрального сканирования; 5-персональный компьютер; 6-ПЛК; 7-актюатор устройства отбраковки; 8-частотный преобразователь; 9-привод конвейера (мотор-редуктор); 10-емкость для пригодной продукции; 11-емкость дефектной продукции.; 12-датчик скорости.

Достоинством гиперспектрального подхода является его способность выявлять дефекты, недоступные для традиционного RGB-анализа. Незаметные глазу микрповреждения, начальные стадии заболеваний, изменения структуры кожицы могут быть обнаружены благодаря комплексному спектральному профилированию [35, 36]. Более того, метод Жирковой поддерживает реализацию в режиме реального времени и

допускает интеграцию в непрерывный производственный цикл, обеспечивая автоматическую отбраковку дефектной продукции с высокой степенью достоверности.

Однако, система требует значительных вычислительных ресурсов. Обработка гиперспектрального куба в реальном времени, требует либо массивного параллельного вычисления, либо предварительной оптимизации, что ограничивает скорость обработки при массовом производстве. В условиях высокоскоростного конвейера это может стать узким местом, особенно при большом потоке продукции.

1.4.3 Электрические и оптические методы контроля качества

Метод, разработанный Сергеем Афанасьевичем Родиковым, представляет собой гибридный подход к неразрушающей диагностике качества яблок, сочетающий в себе электрические и оптические средства анализа для комплексной оценки физиологического состояния плодов. Данный подход направлен на не столько сортировку по внешним признакам, сколько на раннюю диагностику процессов старения, утраты тургора и внутренних метаболических изменений, критичных при хранении и транспортировке фруктов. Метод применения в ситуациях, где необходимо спрогнозировать срок жизнеспособности яблока, не нарушая его целостности.

В основе метода лежат два взаимодополняющих диагностических канала: измерение электрического сопротивления тканей и анализ отражательных и флуоресцентных характеристик кожуры (рис. 1.9).

Преимуществом метода является его неинвазивность, то есть ни один из компонентов системы не требует повреждения кожицы или извлечения материала. Это делает подход крайне ценным в задачах длительного мониторинга партии продукции, например, при закладке на хранение в газовой среде. Кроме того, высокая корреляция между электрическими и оптическими характеристиками и стадией зрелости позволяет использовать

метод как инструмент определения оптимальных сроков сбора, сортировки, хранения и реализации [128, 129].




Рис. 1.9. Схема приставки к спектрофотометру СФ-26 для измерения коэффициентов отражения поверхности яблок: 1-световод, 2-общий конец световода, 3-бленда, 4-объект измерения (яблоко), 5-приемный отводок световода, 6-щель спектрофотометра СФ-26, 7-выходной отводок световода, 8-фотоэлемент СФ-26, 9-приспособление для крепления общего конца световода, 10-прижимное устройство объекта измерения, 11-фиксирующее устройство приемного отводка световода, 12-фиксирующее устройство выходного отводка световода, 13-куветное отделение СФ-26

Тем не менее, несмотря на свою универсальность и научную обоснованность, метод имеет существенные ограничения, если рассматривать его как основу для автоматической сортировки яблок, направляемых на сок. В частности, такой подход способен сигнализировать о нарушении метаболизма, но не указывает локализацию или объём поражения. Это означает, что он скорее информирует о тенденции к ухудшению, чем о наличии ярко выраженного дефекта [130, 131].

Данный метод представляет собой мощный инструмент лабораторной диагностики и прогностической оценки, но не может быть признан достаточным для решения задачи детектирования гнили в потоке.

1.4.4 Оптический метод на основе флуоресценции хлорофилла

Метод, разработанный Абделхамидом Махмудом Абделхамидом Абделтавабом, представляет собой оптико-физиологический подход к оценке зрелости плодов, основанный на регистрации хлорофилловой флуоресценции. Первоначально ориентированный на анализ зрелости томатов, данный метод может быть адаптирован и для других плодовых культур, включая яблоки, особенно в тех технологических процессах, где важно зафиксировать момент перехода от технической зрелости к биологической [30, 31].

В основе метода лежит способность излучать флуоресценцию при возбуждении светом определённой длины волны. При поглощении фотонов происходит кратковременное накопление энергии, которая затем высвобождается в виде светового сигнала в красной и ближней ИК-области (в диапазоне 685 и 735 нм). Этот сигнал, регистрируемый с помощью фотодиодов или специализированных флуориметров, тесно связан с функциональным состоянием фотосинтетического аппарата плода [158, 159].

Архитектурно метод реализован в виде компактного устройства (рис. 1.10), состоящего из управляемого источника возбуждающего излучения, оптической системы с фильтрацией, приёмного фотосенсора, усилительного тракта и микроконтроллера, передающего данные в аналитическую систему.




Рис. 1.10. Функциональная схема устройства для контроля степени зрелости плодов: 1 – объект исследования, 2 – светофильтр, 3 – управляемый источник питания СД (светодиода, типа ARPL-3W-EPL40), 4 – усилитель для ФД (фотодиода, типа ФД-7К), 5 – микроконтроллер, 6 – компьютер.

Достоинством подхода является его высокая чувствительность к физиологическим изменениям, которые происходят задолго до проявления визуальных признаков старения или порчи. Это делает метод особенно ценным в логистике и хранении, позволяя определить оптимальный момент съёма плодов, а также прогнозировать их жизнеспособность на стадии отгрузки и распределения. Метод неинвазивен, не требует контакта и легко может быть встроен в автоматизированную систему контроля качества на линии [30, 158].

Однако в контексте задач, связанных с отбраковкой яблок на сок, метод демонстрирует ряд ограничений. В первую очередь, он фокусируется исключительно на фотосинтетической активности и не предоставляет информации о нарушениях структуры, вызванных гнилью. Кроме того, невозможность оценки степени повреждения плода ограничивает использование данного метода для решения задач промышленной сортировки яблок.

Таким образом, рассмотренные методы не позволяют в полной мере интегрировать их для реализации автоматической сортировки яблок при производстве сока.

1.5 Системы технического зрения для распознавания дефектов плодов

Автоматизация процессов сортировки яблок с применением систем технического зрения является важным направлением развития в пищевой промышленности. Эти системы позволяют значительно повысить эффективность и точность оценки качества плодов, исключая ошибки, связанные с человеческим фактором. СТЗ применяются для анализа таких параметров, как форма, цвет, размер и наличие видимых дефектов на поверхности плодов. Для производства яблочного сока особенно важен тщательный отбор плодов, так как качество сырья напрямую влияет на вкус, аромат и срок хранения конечного продукта.

Особое внимание уделяется выявлению повреждений, которые могут указывать на значительные внутренние дефекты. СТЗ предоставляют возможность оценивать площадь потенциального внутреннего повреждения на основе видимых дефектов на кожице. Если поверхность яблока поражена пятнами гнили или другими повреждениями, это может свидетельствовать о глубоком поражении плода изнутри. Поэтому точное определение внешних дефектов играет ключевую роль в предотвращении попадания низкокачественного сырья в переработку и улучшает качество готового сока.

Внедрение систем технического зрения также открывает возможности для стандартизации процессов сортировки и уменьшения производственных потерь. В перспективе такие системы могут адаптироваться к различным условиям и типам сырья, обеспечивая высокую гибкость производства. Это позволяет предприятиям поддерживать высокий уровень стабильности качества при любых объёмах производства и в условиях колебаний на рынке сырья [87, 88].

Метод, разработанный Петром Петровичем Казакевичем и его исследовательской группой, представляет собой высокоэффективную систему автоматической сортировки яблок, построенную на базе алгоритмов технического зрения и глубокого обучения. Основной акцент делается на идентификацию и классификацию внешних дефектов, в том числе механических повреждений, пятен, болезненных изменений и иных нарушений целостности кожуры (рис 1.11).

В технической реализации система включает блок высокоскоростных камер, размещённых над лентой транспортёра. Благодаря специально организованному вращению плодов, камеры фиксируют серию изображений каждого яблока с разных ракурсов, формируя многоплановое визуальное представление поверхности. Такой подход обеспечивает полноту визуального охвата, критически важную для точного обнаружения дефектов, находящихся вне зоны прямой видимости с одной позиции [89, 90].

Процесс обработки начинается с этапа захвата изображения, далее идёт программное обеспечение на основе алгоритмов компьютерного зрения, которое выделяет яблоко из общего фона, определяет его контур и сегментирует потенциально проблемные области. Для классификации дефектов используется система, основанная на глубокой нейросетевой архитектуре, обученной на массиве размеченных изображений различных повреждений. Благодаря этому сеть способна дифференцировать визуальные паттерны: от простых пятен и проколов до сложных по структуре следов болезней или воздействия вредителей.




Рис. 1.11. Общий вид автоматизированной сортировочной станции плодов: 1 – оптический модуль; 2 – электронный блок управления; 3 – конвейер.

Заключительным этапом становится присвоение плоду категориального признака качества: высший, первый, второй сорт или брак. Эти данные поступают в систему управления сортировочной линией, где актуаторы направляют каждый плод в соответствующий приёмный контейнер. Такая схема обеспечивает полную автоматизацию процесса без необходимости визуального контроля оператором.

Однако, несмотря на высокую эффективность в задачах внешнего контроля, метод демонстрирует определённые ограничения в контексте задач,

связанных с сортировкой яблок для последующей переработки в сок. Прежде всего, система ориентирована на выявление поверхностных дефектов, и потому может ошибочно отбраковывать плоды, обладающие лишь незначительными повреждениями кожуры, не влияющими на химико-биологическое качество мякоти.

Таким образом, данный метод является одной из наиболее продвинутых реализаций систем технического зрения для задач внешней сортировки, особенно эффективной в логистике и товарной упаковке свежих плодов. Однако в контексте задач контроля, ориентированного в том числе на оценку степени повреждения и отбраковку гнилых яблок, метод оказывается недостаточным и требует модификации.

Другой подход к разработке устройства сортировки яблок по сортам приведен в [168]. Здесь также используется СТЗ и сверточная нейронная сеть (СНС) (рис. 1.12).




Рис. 1.12. Схема конвейера-классификатора яблок [168]. 1- конвейерная лента; 2 – камера технического зрения; 3 – персональный компьютер; 4 – лазерный датчик; 5 – исполнительный механизм; 6 – мотор-редуктор; 7 – плод.

Здесь используется полностью разработанная (кастомная) СНС, которая демонстрирует высокую точность классификации (96,88%) сортов яблок и бинарного определения дефектов и оптимизирована под конкретные признаки. Однако такой способ реализации не оценивает площадь (степень) повреждений, слабо адаптируется к новым дефектам или сортам без дообучения, а также подвержен риску переобучения [169, 170].

Для повышения эффективности СТЗ необходимо разработать подходы, которые позволят системе интерпретировать видимые дефекты как индикаторы внутренних нарушений, оценивать закономерности между внешними признаками и состоянием внутренних тканей, чтобы точнее предсказывать степень поражения [1, 3].

Перспективным здесь представляется реализация комплексного подхода, дополняющего сверточную нейронную сеть алгоритмами нечеткой логики. Такая организация системы позволяет преодолеть ограничения традиционных систем технического зрения и значительно повысить точность выявления дефектов. Применение таких алгоритмов особенно важно, когда необходимо учитывать сложные и неоднозначные признаки повреждений, такие как пятна гнили, которые могут варьироваться по форме, размеру и интенсивности. Нейронные сети и нечеткая логика открывают возможности для адаптации СТЗ к разным условиям производства и для улучшения процесса сортировки [27, 29].

Алгоритмы нечеткой логики, в свою очередь, позволяют моделировать ситуации, где нет чётких границ между качественными и дефектными плодами. В отличие от классических логических алгоритмов, которые оперируют бинарными значениями, нечеткая логика даёт возможность оценивать дефекты в процентах или диапазонах. Это особенно полезно при сортировке яблок с частичными повреждениями, когда необходимо решить, следует ли отбраковать плод или направить его на переработку.

Таким образом, обзор существующих методов и технических средств выявил их ограниченность при решении задачи автоматизированной

сортировки яблок для производства сока. Наибольшие сложности связаны с распознаванием внутренних повреждений и необходимостью комплексной оценки качества плодов в условиях поточного производства. Для преодоления этих ограничений предложена архитектура интеллектуальной системы, объединяющей методы компьютерного зрения, алгоритмы глубокого обучения и средства нечеткой логики. Общая структура разработанной системы представлена на рисунке 1.13.




Рис. 1.13. Структура информационно-управляющей системы сортировки яблок: 1 – персональный компьютер; 2 – высокопроизводительный сервер; 3 – электропривод транспортера; 4 – роликовый транспортер; 5 – направляющие транспортера; 6, 8 – направляющие сортировщика; 7 – емкость для поврежденных яблок; 9 – плоды; 10 – камера; 11 – программируемый логический контроллер; 12 – серверы для управления

технологическим оборудованием; 13 – набор данных для обучения и тестирования сверточной нейронной сети; 14 – сортировочный узел; 15 – заслонки с позиционным (электромагнитным) приводом.

1.6 Цель и задачи исследования

Цель исследования: разработка и научное обоснование методов повышения эффективности процесса сортировки плодов на основе применения систем технического зрения.

Для достижения поставленной цели необходимо решить следующие задачи:

1. разработать математическую модель, связывающую предполагаемый объем повреждения плода гнилью с площадью поверхности дефекта;
2. разработать модель нечеткой логики с приоритетной иерархией принятия решений для классификации яблок по категориям качества;
3. разработать алгоритмическое обеспечение и программную реализацию системы автоматизированной оценки качества плодов при сортировке;
4. разработать методику и физическую модель автоматизированной системы сортировки яблок с использованием системы технического зрения;
5. теоретически и экспериментально с использованием математического моделирования и теории планирования многофакторного эксперимента оценить влияние наиболее значимых факторов на выходные показатели автоматизированной системы сортировки – ошибку классификации и производительность.

1.7 Выводы по первой главе

В первой главе рассмотрены перспективы развития производства яблочного сока в России, выявлена актуальность задачи повышения эффективности процесса сортировки яблок как одного из ключевых этапов

производства. Проанализированы основные этапы технологии производства яблочного сока, где особое внимание уделено этапу сортировки и отбора плодов, как определяющему качество и безопасность конечного продукта.

Проведена классификация основных типов повреждений плодов, включая механические, биологические и физиологические, и определено их влияние на качество яблочного сока. Особое внимание уделено проблеме выявления скрытых дефектов, в частности, гнили, которые могут оказывать существенное негативное влияние на органолептические свойства и микробиологическую стабильность сока.

Осуществлен обзор существующих методов и технических средств оценки качества яблок, включая методы на основе цветных телевизионных датчиков, гиперспектрального анализа, электрических и оптических методов контроля. Показаны ограничения каждого из рассмотренных методов, в частности, их недостаточная эффективность в выявлении внутренних дефектов и оценке степени повреждения плодов. Представлен анализ применения систем технического зрения для распознавания дефектов плодов, выявлены преимущества и недостатки существующих подходов. Сделан вывод о необходимости разработки системы компьютерного зрения, основанной на комбинировании сверточных нейронных сетей и алгоритмов нечеткой логики, для повышения эффективности и точности сортировки яблок при производстве сока.

2. ТЕОРЕТИЧЕСКИЕ ПРЕДПОСЫЛКИ РЕАЛИЗАЦИИ АЛГОРИТМА КОСВЕННОЙ ОЦЕНКИ КАЧЕСТВА ПЛОДОВ ПРИ АВТОМАТИЗИРОВАННОЙ СОРТИРОВКЕ

2.1 Постановка задач

Для продукции, связанной с переработкой фруктового сырья, особенно важно разработать комплексную систему контроля, основанную на анализе изображений, автоматической оценке повреждений и построении процесса сортировки с опорой на интегрированную нечеткую модель принятия решений. Цель разработки интеллектуальной системы автоматического управления сортировкой яблок сводится к построению целостного алгоритма оценки качества плодов, который будет способен автономно распознавать объекты, выделять на их поверхности области поражения, вычислять относительные значения площади и объема повреждений, а затем на основе нечеткого вывода и предзаданной иерархии решений классифицировать яблоки по технологическим категориям. Реализация такой задачи возможна только при совмещении методов компьютерного зрения, машинного обучения и нечеткого моделирования [171, 172].

Построение системы базируется на идеологии каскадной архитектуры, при которой каждый модуль выполняет строго определенную функцию в технологической цепочке обработки.

Проектирование интеллектуальной системы осуществляется с учетом необходимости работы в условиях высокой изменчивости свойств продукции, включая особенности формы, расцветки, неоднородности фона, различий в освещении, а также технологических ограничений, накладываемых скоростью конвейера и др [2, 6, 10].

Целевое назначение системы заключается в реализации полной автоматизации оценки качества яблок на основе визуальной информации и принятии решений о технологической реализации продукции. В рамках задачи предусмотрено шесть выходных категорий: «Продажа», «Хранение», «Сок»,

«Пюре», «Корм животным» и «Утиль», определение которых осуществляется с учетом интеграции количественных и качественных характеристик.

К числу функциональных задач, необходимых решению в рамках построения интеллектуальной системы, относятся:

- разработка обобщенной схемы алгоритма управления автоматизированной сортировки;
- оценка геометрических параметров яблок (площадь, объем);
- выделение и классификация областей повреждения на основе контурного анализа и вывода сверточной нейронной сети;
- расчет относительных показателей гнили к общему объему и площади плода;
- реализация алгоритма косвенной оценки состояния продукции при ограниченной информации;
- визуализация алгоритма косвенной оценки объема повреждения плодов;
- построение нечеткой логической модели, учитывающей неопределенности и пограничные состояния, с приоритетной иерархией принятия решений.

2.2 Разработка обобщенной схемы алгоритма управления автоматизированной сортировкой

Разработка и эффективное представление алгоритмов управления (АУ) технологическими процессами (ТП) имеет первостепенное значение для анализа, моделирования, внедрения и оптимизации автоматизированных систем. На выбор способа формализации алгоритма влияет сложность процесса, требуемый уровень детализации, квалификация персонала и цели, преследуемые при разработке системы управления.

При этом, в виду возрастающей сложности, динамичности и требованиям к гибкости технологических процессов применение

существующих подходов к описанию и визуализации АУ является затруднительным.

Перспективным подходом представляется использование нотаций *BPMN* (*Business Process Model and Notation*) – это стандартизированный графический язык, предназначенный для моделирования бизнес-процессов и обладающий значительным потенциалом для применения в разработке алгоритмов управления технологическими процессами

Использование нотаций позволяет моделировать случаи, характерные при автоматическом управлении, включая последовательные процессы, параллельное выполнение задач, ветвления на основе условий, циклы и обработку исключительных ситуаций, что дает возможность имитировать сложные правила принятия решений и логику переключения между различными ветвями алгоритма [12, 14, 22].

BPMN поддерживает моделирование взаимодействия между различными системами и участниками технологического процесса посредством пулов и дорожек. Пулы представляют собой контейнеры для процессов, выполняемых распределенными системами, а дорожки – для процессов, обрабатываемых различными узлами/модулями внутри одной системы. Это позволяет моделировать сложные взаимодействия, например, передачу данных между датчиками, контроллерами и исполнительными механизмами.

На рисунке 2.1 приведена обобщенная схема алгоритма управления автоматизированной сортировкой.

Предложенный алгоритм (рис. 2.1), основанный на анализе площади поврежденной поверхности, представляет собой многоступенчатый процесс, интегрирующий систему технического зрения, модуль предобработки изображений, нейронные сети для сегментации и регрессии, а также подсистему хранения и визуализации результатов. Процесс организован в соответствии с принципами *BPMN*, где ключевые функциональные блоки представлены в виде отдельных дорожек внутри единого пула.

Система технического зрения отвечает за первичный захват визуальной информации. Инициализация аппаратной платформы предполагает настройку камер для получения оптимального разрешения и частоты кадров, а также калибровку системы освещения для обеспечения равномерности и исключения артефактов.

На этапе захвата изображения плода проводится контроль ориентации яблока. Многократная съемка под разными углами позволяет получить объемную реконструкцию и более точную оценку площади повреждения. Полученный набор изображений сохраняется в буфер или на локальный диск для дальнейшей обработки. Завершающим этапом этой дорожки является передача данных в модуль предобработки, где формируется структурированный поток изображений, включающий идентификатор партии, координаты яблока на ленте и время съемки.




Рис. 2.1. Обобщенный алгоритм управления автоматизированной сортировкой

Модуль предобработки изображений осуществляет подготовку полученных изображений для последующего анализа нейронными сетями. Первоначально проводится проверка качества входных данных, включающая анализ метаданных изображений и отбраковку кадров, не соответствующих установленным критериям, например, слишком темные или размытые. Далее применяются методы коррекции и фильтрации для улучшения качества изображений. Для облегчения выделения дефектов проводится нормализация цвета и выделение контуров яблока. При необходимости осуществляется преобразование цветовой модели, а также выполняется поиск и фиксирование координат границ плода. Подготовленные изображения сохраняются во временное хранилище и передаются в очередь для обработки нейронной сетью [22, 24].

Сверточная нейронная сеть (СНС) реализует ключевой этап анализа – сегментацию повреждений и оценку их объема. Первоначально происходит инициализация и загрузка предварительно обученной модели сегментации повреждений, например, *YOLO*. Устанавливаются параметры порога доверия для определения сегмента дефекта.

На этапе выделения областей повреждений запускается сегментация на каждом предобработанном изображении, формируется маска поврежденных участков и проводится опциональная постобработка для удаления ложных срабатываний и сглаживания контуров.

2.3 Разработка алгоритма косвенной оценки объема повреждения плодов

2.3.1 Математическая модель зависимости объема повреждения плода от площади дефекта

Этап определения площади и объема повреждения плода является центральным компонентом интеллектуальной системы оценки состояния продукции. Именно на этом этапе производится количественная характеристика повреждений, что обеспечивает основу для принятия решений

в системе сортировки. Расчет реализуется в подзадачах «Определения площади плода повреждения» и «Регрессионная оценка объема повреждения» (рис. 2.1).

Задача регрессионного блока связать площадь повреждения с предполагаемым объемом, опираясь на эмпирические данные распространения заболевания внутрь плода:

$$k_V = f(k_S), \quad (2.1)$$

где k_V, k_S – относительный объем и площадь повреждения.

$$k_S = \frac{S_{\text{повр}}}{S_{\text{ябл}}}, \quad (2.2)$$

$$k_V = \frac{V_{\text{повр}}}{V_{\text{ябл}}}, \quad (2.3)$$

где $S_{\text{повр}}, V_{\text{повр}}$ – площадь и объем повреждения; $S_{\text{ябл}}, V_{\text{ябл}}$ – площадь и объем плода.

Для определения значений k_V, k_S введем ряд условий и ограничений. В частности, для оценки порядка величины дефекта аппроксимация плода в виде сферы и повреждения в виде полусферы представляется достаточным. Данный подход выбран в связи с необходимостью анализа большого количества образцов и упрощения алгоритма косвенной оценки.

С учетом допущений определим площадь поверхности $S_{\text{ябл}}$ и объем $V_{\text{ябл}}$ плода 2 (рис. 2.2):

$$S_{\text{ябл}} = 4\pi R^2, \quad (2.4)$$

$$V_{\text{ябл}} = \frac{4}{3}\pi R^3, \quad (2.5)$$

где $R = \frac{R_{\min} + R_{\max}}{2}$ – среднее расчетное значение радиуса плода; $R_{\min}, R_{\max}$ – меньший и больший измеренные радиусы плода.




Рис. 2.2. Расчет степени повреждения плода

Определим площадь повреждения $S_{\text{повр}}$ с учетом ее аппроксимации в виде полусферы (рис. 2.2):

$$S_{\text{повр}} = \pi(r^2 + h^2), \quad (2.6)$$

где r – радиус основания повреждения, $h = R - \sqrt{R^2 - r^2}$ – высота полусферы.



Рис. 2.3. Оценка объема $V_{\text{повр.}}$ повреждения плода гнилью в зависимости от площади дефекта

В процессе разработки учитывались реальные данные, полученные при экспериментальных исследованиях с различными партиями плодов, что позволило скорректировать ряд гипотез и эмпирических зависимостей, связанных с формой распространения гнили (рис. 2.3), зависимостью между

площадью поражения и объемом поврежденного участка, а также погрешностями в оценке формы плода при отклонениях от сферической модели (таблица 2.1, приложение 1).

Таблица 2.1 Экспериментальные данные параметров плодов с разной степенью поражения

Наименование	Ø ябл. мм.	Ø забол. мм.	М всего яблока	М яблока без гнили	Δм	Плотность	Объем яблока
1	72	36	158	143	15	7,317115761	19,54321958
2	72	55	154	100	54	5,116864168	19,54321958
3	67	34	119	102	17	6,477048385	15,74791385
4	62	56	82	55	27	4,407466283	12,4788249
5	110	35	217	197	20	2,826763978	69,69099703
6	68	40	110	100	10	6,07399793	16,46362102
7	74	43	137	106	31	4,995880985	21,21747902
8	65	23	100	93	7	6,46761644	14,37933137
9	75	46	195	179	16	8,103462347	22,08932335
10	65	54	124	114	10	7,928045959	14,37933137
11	68	36	146	133	13	8,078417247	16,46362102
12	57	31	65	57	8	5,878298914	9,696682805
13	68	55	127	105	22	6,377697826	16,46362102
14	74	60	184	150	34	7,069642903	21,21747902
15	68	32	128	114	14	6,92435764	16,46362102
16	59	18	77	75	2	6,974396057	10,75361929
17	69	32	123	119	4	6,918326704	17,20069102
18	76	32	155	150	5	6,526071985	22,98472961
19	101	31	83	69	14	1,27904654	53,94643421
20	101	38	217	159	58	2,947368113	53,94643421
21	117	36	193	154	39	1,836388284	83,86026058
22	116	25	101	79	22	0,966617161	81,72832344
23	117	21	180	163	17	1,943709677	83,86026058

С учетом эмпирических данных о распространении гнили внутрь плода (рис. 2.3, приложение 1) определим объем повреждения 1 (рис. 2.2):

$$V_{\text{повр}} = \frac{V_{\text{повр}}^{\text{пс}} + V_{\text{повр}}^{\text{сек}}}{2}, \quad (2.7)$$

где $V_{\text{повр}}^{\text{пс}}$, $V_{\text{повр}}^{\text{сек}}$ – распространение гнили в виде полусферы 3 и сектора 4 (рис. 2.2).

$$V_{\text{повр}}^{\text{пс}} = \frac{2}{3}\pi r^3 + \pi h^2 \left(R - \frac{h}{3} \right), \quad (2.8)$$

$$V_{\text{повр}}^{\text{сек}} = \frac{2}{3} \pi r^2 h - \pi h^2 \left(r - \frac{h}{2} \right) + \pi h^2 \left(R - \frac{h}{2} \right). \quad (2.9)$$

С учетом (2.4)–(2.9) на рис. 2.4 представлена функция (2.1). Точками показаны эмпирические данные зависимости относительного объема гнили от площади повреждения (табл. 2.1).




Рис. 2.4 Аппроксимирующие диаграммы зависимости $k_v=f(k_s)$

Аппроксимирующие диаграммы 1, 2, 3 (рис. 2.4) характеризуют данные, рассчитанные соответственно по $V_{\text{повр}}^{\text{ПС}}$, $V_{\text{повр}}$, $V_{\text{повр}}^{\text{сек}}$. Их анализ показывает, что среднее значение $V_{\text{повр}}$ наилучшим образом описывает реальный объем повреждения плода гнилью в зависимости от площади дефекта [164].

2.3.2 Разработка и визуализация алгоритма косвенной оценки объема повреждения плодов

С учетом математического моделирования (п.п. 2.31) разработан алгоритм косвенной оценки зависимости объема повреждения плодов гнилью от площади дефекта. Результат визуализации представлены в виде *BPMN*-диаграммы на рис 2.5




Рис. 2.5. Визуализация алгоритма косвенной оценки объема повреждения плодов гнили в зависимости от площади дефекта

Процесс начинается с определения меньшего R_{min} и большего R_{max} радиусов плода. Эти параметры извлекаются из анализа контуров плода, полученных на этапе обработки изображений. Расчет производится путём построения минимальной описанной окружности и максимальной протяженности объекта, что позволяет учесть возможную асимметрию плода.

На основании найденных радиусов вычисляется среднее расчетное значение радиуса плода R , которое используется в дальнейших вычислениях. Для получения корректной площади поверхности плода предполагается приближение формы объекта к сферической модели, что оправдано особенностями геометрии большинства сортов яблок.

Параллельно производится определение радиуса основания полусферы повреждения r , который извлекается из выделенной маски дефекта.

Для последующего расчета параметров повреждения необходимо определить высоту h полусферы дефектной области. Высота определяется через соотношение между радиусами r и R и используется для уточнения формы повреждённого участка. Предполагается, что дефектная зона

аппроксимируется полусферой, что позволяет использовать классические формулы расчёта площадей и объемов геометрических тел.

Площадь поврежденной поверхности $S_{\text{повр}}$ определяется с использованием уравнений для части сферы. После получения площади дефектной зоны производится расчет относительной площади повреждения плода k_S , которая выражается в процентах от общей площади поверхности.

Одновременно с расчетом площади производится регрессионная оценка объема повреждения. Данный этап разделен на две модели аппроксимации: расчет объема повреждения как полусферы $V_{\text{повр.пс}}$ и как сферического сектора $V_{\text{повр.сек.}}$. Каждая из моделей использует различные зависимости между радиусом, высотой и площадью дефектной области.

Объем поврежденного участка определяется через усреднение результатов двух моделей, что позволяет повысить точность оценки при наличии отклонений формы дефекта от идеальной полусферы. Среднее значение объема повреждения обозначается как $V_{\text{повр.}}$. Система получает две независимые оценки степени повреждения: по площади k_S и по объему k_V , что позволяет проводить комплексную диагностику состояния плодов и более точно классифицировать их качество.

2.4 Математическое моделирование неопределенности и пограничных состояний плодов в нечеткой логике с приоритетной иерархией решений

2.4.1 Агрегация и верификация результатов

После расчета значений относительной площади повреждения k_S и относительного объема повреждения k_V система переходит к этапу агрегации и верификации результатов. Этот процесс служит связующим звеном между блоком количественного анализа дефектов и системой принятия решений по дальнейшей сортировке продукции (рис. 2.1).

На первом этапе осуществляется прием расчетных данных о площади и объеме повреждения плодов. Значения k_S и k_V передаются в агрегирующий

модуль, который обеспечивает целостность данных и формирует единый формат представления информации для последующего анализа. На данном этапе также проводится проверка корректности переданных параметров: допустимость диапазонов значений, отсутствие аномалий и пропусков данных.

Следующим этапом является сопоставление принятых данных с внутренними пороговыми значениями, заданными в системе. Пороговые значения определяют допустимые пределы повреждений, при которых плод может быть отнесен к определенной категории качества или направлен на соответствующую переработку. Пороговые параметры устанавливаются на основе предварительных экспертных оценок, экспериментальных данных, а также анализа требований стандартов качества для конкретных сортов продукции [112, 126, 127].

Процесс сопоставления предполагает классификацию состояния плода на основе логических правил: если k_S и k_V превышают определенные пороги, плод считается имеющим значительные повреждения и требует специальной обработки; в случае нахождения параметров в допустимых пределах, плод может быть направлен на продажу или хранение. Эта процедура является предварительной фильтрацией перед более сложной обработкой в модуле принятия окончательных решений, где подключаются методы нечёткой логики [38, 107, 112].

Таким образом, этап агрегации и верификации результатов обеспечивает формирование структурированной, проверенной и стандартизированной информационной базы для высокоточного и надёжного функционирования системы сортировки.

2.4.2 Возможности нечеткой логики в моделировании степени повреждения плодов

Процесс управления сортировкой яблок в рамках разработанной системы представляет собой последовательность логических и

вычислительных процедур, направленных на интерпретацию визуальной информации, извлечение ключевых признаков и принятие решений на основе гибкой логической модели. В отличие от классических систем, основанных на бинарной классификации, здесь используется более сложная архитектура, позволяющая работать с размытыми и неполными данными. Это стало возможным благодаря интеграции методов нечёткой логики и построению иерархии правил, отражающей реальную специфику сортировки фруктов с множеством промежуточных состояний [140, 152, 162].

Математическая модель управления строится как совокупность функций принадлежности и логических правил, формирующих базу знаний в терминах нечёткой логики. Каждому параметру сопоставлены лингвистические переменные, например: «объём повреждения – высокий», «цвет – соответствует», «размер – малый». Функции принадлежности построены на основе экспериментальных данных и экспертных наблюдений, а границы сегментов уточнены через аппроксимацию эмпирических зависимостей. Это позволяет адекватно отразить размытые границы между категориями, что характерно для фруктовой продукции.

Входными данными в системе являются числовые параметры, полученные в результате предварительной обработки изображений и геометрических вычислений, а также характеристики, полученные в результате работы сверточной нейронной сети. К числу таких параметров относятся: относительная площадь повреждения k_s , относительный объём повреждения k_v , значения цветовых характеристик (в частности, компонента RGB), геометрическая форма плода (определяемая по эксцентриситету и пропорциям), а также размерные параметры, включающие в себя меньший и больший радиусы R_{min} , R_{max} , и производный средний радиус R . Все эти признаки являются результатом количественной обработки визуальной информации и могут быть подвергнуты формализации через систему функций принадлежности, что позволяет эффективно интегрировать их в блок нечёткой логики.

Таким образом, входные данные в системе представляют собой комплекс разнотипных количественных характеристик, которые после прохождения этапа фаззификации поступают в логический блок. Итоговое значение, получаемое в результате дефаззификации и применения приоритетной иерархии правил, определяет путь дальнейшей сортировки продукции. Корректность анализа и полнота охвата параметров на этом этапе критичны для обеспечения точности и адаптивности всей интеллектуальной системы управления.

На выходе системы управления формируется однозначное управляющее воздействие – присвоение каждой единице продукции одной из доступных категорий сортировки. Количество таких категорий, с учётом требований производственного цикла и технологических сценариев, составляет шесть: «Продажа», «Хранение», «Сок», «Пюре», «Корм животным» и «Утиль». Каждая категория связана с определённым набором критериев, включающих допустимый уровень повреждения, приемлемую форму и размер, а также соответствие внешнего вида установленным стандартам сорта.

Оптимизируемые параметры в системе условно разделяются на две группы: параметры объекта и параметры логического моделирования. К первой группе относятся признаки, описывающие физическое состояние и визуальные характеристики плода, извлекаемые из изображений и метрических оценок. К числу таких параметров относятся относительный объём повреждения k_V , относительная площадь дефекта k_S , значение компоненты RGB, а также размер плода, полученный на основе анализа радиусов R_{min} , R_{max} и их среднего значения R . Все перечисленные параметры поддаются численному измерению и представляют собой входную информацию, критически важную для функционирования блока фаззификации [24, 28, 107].

Во вторую группу входят параметры конфигурации функций принадлежности и логических правил, определяющих границы между лингвистическими значениями. К числу таких параметров относятся

пороговые значения a и b в функциях принадлежности, тип функции (треугольная, трапецевидная), ширина переходной зоны, приоритеты логических правил и веса при дефаззификации, если используется агрегирующая модель. В классической системе типовая функция принадлежности для переменной x может быть задана в виде:

$$\mu(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x < b \\ 1, & x \geq b \end{cases}, \quad (2.10)$$

где a и b – пороговые значения, определяемые на основе эмпирических наблюдений или анализа распределения признака по множеству обучающих объектов. Ошибки в задании этих значений могут приводить к смещению оценки или к избыточной жёсткости границ, из-за чего система теряет адаптивность.

2.4.3 Выбор лингвистических переменных и построение базы правил

Применение нечеткой логики позволяет учитывать неопределённость и размытость границ между состояниями объектов, характерную для аграрной продукции, в частности плодов с неоднородной геометрией, цветом и степенью повреждений. Вместо жёсткого порогового деления здесь реализуется система мягких переходов между классами, основанная на оценке степени принадлежности объекта к тому или иному лингвистическому признаку [37, 59, 69].

Построение базы правил осуществляется на основе набора входных переменных, каждая из которых преобразуется в лингвистическую форму с помощью функций принадлежности. Эти переменные охватывают критически важные свойства объекта: объём повреждения, цвет, форму и размер плода. Каждая из этих характеристик интерпретируется через ограниченное количество лингвистических значений – например, «малый», «средний» и

«высокий» для объёма повреждения – что позволяет упростить логику вывода, сохранив при этом достаточную чувствительность системы.

Для формализации базы правил использовалась типовая структура *IF–THEN*, где условная часть описывает комбинацию лингвистических состояний входных переменных, а заключение определяет категорию сортировки. Например: *если объём повреждения высокий, то направить в утиль*. Для других ситуаций формулируются более сложные правила, в которых одновременно анализируются цвет, форма и размер – что отражает интегративный подход к оценке качества.

В основе реализации нечёткой экспертной системы лежит подход Сугено нулевого порядка. Такая архитектура позволяет выполнять логический вывод с минимальными вычислительными затратами, что особенно важно при поточном принятии решений в условиях реального времени. Входными переменными системы являются параметры, описывающие состояние плода: степень повреждения «*D*», соответствие цвета эталону «*C*», форма «*F*» и размер «*S*».

Лингвистическая переменная «*D*» – степень повреждения плода. Универсальное множество переменной «*D*» соответствует доле объёма плода, охваченного дефектом. Значение изменяется в пределах от 0 (отсутствие повреждений) до 1 (полное поражение). Для представления степени повреждения введены три терма: «Малый», «Средний» и «Высокий», соответствующие лингвистическим оценкам уровня дефекта.

Функции принадлежности (2.10) этих термов определены на основе эмпирических наблюдений и экспертной оценки и описываются следующими выражениями:

Функция принадлежности для терма «Малый»:

$$\mu_{\text{мал}}(D) = \begin{cases} 1, & D \leq 0.1 \\ 1 - 10(D - 0.1), & 0.1 < D < 0.2 \\ 0, & D \geq 0.2 \end{cases} \quad (2.11)$$

Функция принадлежности для терма «Средний»:

$$\mu_{\text{ср}}(D) = \begin{cases} 0, & D \leq 0.1 \\ 10(D - 0.1), & 0.1 < D < 0.2 \\ 1, & 0.2 \leq D \leq 0.3 \\ 1 - 5(D - 0.3), & 0.3 < D < 0.5 \\ 0, & D \geq 0.5 \end{cases} \quad (2.12)$$

Функция принадлежности для терма «Высокий»:

$$\mu_{\text{выс}}(D) = \begin{cases} 0, & D \leq 0.3 \\ 5(D - 0.3), & 0.3 < D < 0.5 \\ 1, & D \geq 0.5 \end{cases} \quad (2.13)$$

На рис. 2.6 представлены кривые принадлежности указанных термов, отображающие плавную переходность между категориями повреждённости плода.




Рисунок 2.6. Функции принадлежности лингвистической переменной «D» — степень повреждения плода

Лингвистическая переменная «С» — соответствие цвета плода эталону. Во второй позиции среди входной переменной системы нечёткой логики выступает параметр «С» — соответствие цвета плода эталону, определяющий степень близости реального цвета конкретного яблока к

эталонному значению, принятому для сорта. Поскольку сортировка ориентирована на сорт «Голден», за эталон был принят его усреднённый цвет в RGB -модели: $RGB_{ud} = (220, 255, 200)$.

Каждое поступающее в систему изображение яблока обрабатывается для получения усреднённого значения цвета $RGB_p = (R_p, G_p, B_p)$ по маске плода. Далее рассчитывается евклидово расстояние между эталонным и реальным значением:

$$Dist_{RGB} = \sqrt{(R_p - 220)^2 + (G_p - 255)^2 + (B_p - 200)^2} \quad (2.14)$$

Чтобы сделать это значение пригодным для нечёткой оценки, оно нормируется по теоретически возможному максимуму – это расстояние от $(0, 0, 0)$ до $(220, 255, 200)$. Тогда с учетом (2.14):

$$Dist_{max} = \sqrt{(0 - 220)^2 + (0 - 255)^2 + (0 - 200)^2} \approx 392 \quad (2.15)$$

Таким образом, получаем нормированную метрику цветового отклонения:

$$RN = \frac{Dist_{RGB}}{Dist_{max}} \in [0; 1] \quad (2.16)$$

Для нечёткой оценки RN введены три терма:

- Соответствует – минимальное цветовое отклонение,
- Пограничное значение – допустимое, но уже заметное отклонение,
- Не соответствует – отклонение от сорта выходит за границы допустимого.

Функции принадлежности описаны следующими выражениями:

Терм "Соответствует":

$$\mu_c(RN) = \begin{cases} 1, & RN \leq 0.1 \\ 1 - 10(RN - 0.1), & 0.1 < RN < 0.2 \\ 0, & RN \geq 0.2 \end{cases} \quad (2.17)$$

Терм "Пограничное":

$$\mu_{\Pi}(RN) = \begin{cases} 0, & RN \leq 0.1 \\ 10(RN - 0.1), & 0.1 < RN < 0.2 \\ 1, & 0.2 \leq RN \leq 0.3 \\ 1 - 10(RN - 0.3), & 0.3 < RN < 0.4 \\ 0, & RN \geq 0.4 \end{cases} \quad (2.18)$$

Терм "Не соответствует":

$$\mu_{\text{НС}}(RN) = \begin{cases} 0, & RN \leq 0.3 \\ 10(RN - 0.3), & 0.3 < RN < 0.4 \\ 1, & RN \geq 0.4 \end{cases} \quad (2.19)$$

Графическая интерпретация приведённых функций принадлежности представлена на рис. 2.7. На ней отчётливо прослеживается логика перехода между зонами: левая часть графика охватывает область, где цвет практически идентичен эталону, центральный сегмент соответствует допустимому отклонению, а правая часть сигнализирует о выходе параметра за пределы сортового стандарта.




Рисунок 2.7 Функции принадлежности лингвистической переменной «С» — соответствие цвета плода эталону

Такой подход обеспечивает интерпретируемую и гибкую модель принятия решений при неустойчивых условиях освещения или вариативности

поверхности плода. Благодаря линейным участкам и перекрывающимся термам, достигается необходимая степень нечёткости, отражающая реальную неоднозначность восприятия цвета в производственной среде.

Лингвистическая переменная «F» – форма плода. Следующей лингвистической переменной, определяющей визуальные и геометрические характеристики плода, является «F» – форма плода. Этот параметр особенно важен в контексте оценки сортового соответствия и пригодности яблока к механизированной переработке. Например, слишком вытянутые или асимметричные плоды могут создавать затруднения при автоматической загрузке или резке, а также указывать на отклонения в процессе роста.

Форма плода количественно выражается через отношение минимального диаметра к максимальному:

$$RD = \frac{D_{\min}}{D_{\max}}, \quad (2.20)$$

где $D_{\min}$ - наименьший диаметр плода в проекции, $D_{\max}$ - наибольший диаметр.

Таким образом, величина $RD \in [0; 1]$: при идеальной сферической форме она близка к 1, а при вытянутой или сплюснутой – стремится к 0. На основе анализа эмпирических данных и сортовых требований были введены три термина:

- Сферическая – правильная округлая форма,
- Средняя – допускаются умеренные искажения,
- Эллипсоидная – ярко выраженная вытянутость.

Аналитически эти термы описываются следующим образом:

Терм "Сферическая":

$$\mu_{\text{сф}}(RD) = \begin{cases} 0, & RD \leq 0.8 \\ 10(RD - 0.8), & 0.8 < RD < 0.9 \\ 1, & RD \geq 0.9 \end{cases} \quad (2.21)$$

Терм "Средняя":

$$\mu_{\text{ср}}(RD) = \begin{cases} 0, & RD \leq 0.6 \\ 10(RD - 0.6), & 0.6 < RD < 0.7 \\ 1, & 0.7 \leq RD \leq 0.8 \\ 1 - 10(RD - 0.8), & 0.8 < RD < 0.9 \\ 0, & RD \geq 0.9 \end{cases} \quad (2.22)$$

Терм "Эллипсоидная":

$$\mu_{\text{эл}}(RD) = \begin{cases} 1, & RD \leq 0.6 \\ 1 - 10(RD - 0.6), & 0.6 < RD < 0.7 \\ 0, & RD \geq 0.7 \end{cases} \quad (2.23)$$

Каждая из этих функций принадлежности аппроксимирует экспертную интерпретацию отклонения формы от нормы, обеспечивая устойчивость к незначительным искажениям и позволяя системе гибко реагировать на реальные вариации геометрии плодов.

На рисунке 2.8 представлены кривые принадлежности, иллюстрирующие экспертное восприятие формы яблока. Каждая из кривых демонстрирует диапазон, в котором значение отношения RD соответствует одной из лингвистических категорий. Эллипсоидная форма характерна для плодов с ярко выраженным вытянутым профилем, тогда как сферическая соответствует почти идеальной округлости. Важно отметить, что перекрытие термов не только допустимо, но и отражает реальную нечёткость границ между геометрическими типами. Это обеспечивает системе гибкость при классификации плодов с промежуточными или нестабильными формами




Рисунок 2.8. Функции принадлежности лингвистической переменной «F» – форма плода

Лингвистическая переменная «S» – размер плода. Четвёртая входная лингвистическая переменная системы нечёткой логики обозначается как «S» – размер плода. Этот параметр играет важную роль в маршрутизации продукции: слишком малые плоды могут быть направлены на переработку в пюре, в то время как плоды стандартных размеров – в сок или на хранение. Оценка размера осуществляется на основе измерения поперечного диаметра плода в миллиметрах, определяемого на изображении после сегментации объекта и нахождения габаритного прямоугольника.

На основе экспериментальной выборки ($n = 1200$ плодов сорта «Голден») и требований ГОСТ на калибровку фруктов были выделены три группы:

- Малый: диаметр менее 65 мм,
- Средний: диаметр от 65 до 85 мм,
- Крупный: диаметр более 85 мм.

Для построения функций принадлежности параметр S был нормирован:

$$SN = \frac{S - 50}{100 - 50} \in [0; 1], \quad (2.24)$$

где S – фактический диаметр плода в мм; 50 и 100 – нижняя и верхняя границы допустимого диапазона, используемые для нормализации.

Функции принадлежности определяются следующим образом:

Терм "Малый":

$$\mu_{\text{м}}(SN) = \begin{cases} 1, & SN \leq 0.3 \\ 1 - \frac{SN-0.3}{0.1}, & 0.3 < SN < 0.4 \\ 0, & SN \geq 0.4 \end{cases} \quad (2.25)$$

Терм "Средний":

$$\mu_{\text{с}}(SN) = \begin{cases} 0, & SN \leq 0.3 \\ \frac{SN-0.3}{0.1}, & 0.3 < SN < 0.4 \\ 1, & 0.4 \leq SN \leq 0.6 \\ 1 - \frac{SN-0.6}{0.1}, & 0.6 < SN < 0.7 \\ 0, & SN \geq 0.7 \end{cases} \quad (2.26)$$

Терм "Крупный":

$$\mu_{\text{к}}(SN) = \begin{cases} 0, & SN \leq 0.6 \\ \frac{SN-0.6}{0.1}, & 0.6 < SN < 0.7 \\ 1, & SN \geq 0.7 \end{cases} \quad (2.27)$$

Переменная размера интерпретируется в системе не как жёсткий порог, а как диапазон значений с перекрывающимися зонами, что позволяет корректно обрабатывать случаи, когда размер плода находится на границе между категориями.

Представленные функции принадлежности (2.25) – (2.27) визуализируют (рис. 2.9) интерпретацию размера плода с точки зрения классификационной системы. Модель постепенно переходит от одной категории принадлежности к другой по мере приближения к граничным значениям. Такая плавность не только делает систему устойчивой к случайным измерительным ошибкам, но и отражает реальное распределение размеров в партии: на практике невозможно строго разделить яблоки по размеру, не попадая в серую зону. Именно поэтому перекрытие термов критически важно для корректной маршрутизации продукции.




Рисунок 2.9. Функции принадлежности лингвистической переменной «S» – размер
плода

Таким образом в рамках построения нечёткой экспертной системы для сортировки яблок была сформирована база правил, отражающая логические зависимости между входными параметрами плода (степень повреждения, цвет, форма, размер) и принимаемым решением о его дальнейшем назначении. Каждое правило описывает определённую комбинацию состояний переменных и жёстко фиксирует, к какой категории следует отнести плод при их выполнении.

2.4.4 Реализация иерархической структуры логического вывода

В отличие от классических подходов к построению нечетких систем, где все правила имеют одинаковую значимость и обрабатываются параллельно (как в системах Мамдани или Такаги-Сугено), в разработанной модели реализована приоритетная (иерархическая) структура логических правил. Это означает, что система начинает проверку условий с наиболее значимых, например, высокой степени повреждения, и при выполнении соответствующего правила прекращает дальнейший анализ. Такой подход существенно повышает интерпретируемость модели, ускоряет процесс принятия решений и снижает количество необходимого для реализации правил. Кроме того, этажность логики позволяет формировать контекстные

условия, например, когда значения одних переменных становятся значимыми только в случае выполнения предварительных критериев.

К примеру, если степень повреждения плода достигает высокой величины (например, более 0.6), то независимо от формы, размера или цветовой насыщенности плод подлежит безусловному браку. Именно такая логика и реализована в данной системе: правила, связанные с критическими значениями ключевых параметров, располагаются в начале – они имеют высший приоритет и блокируют остальные уровни анализа. Это позволяет формализовать принцип «жёсткости» на раннем этапе – снижая нагрузку на вычислительные блоки и минимизируя вероятность неопределённости при обработке.

В более мягких случаях, когда параметры находятся в пограничных областях, например, умеренные повреждения и нестабильный цвет, система обращается к следующим уровням логики, в которых учитываются менее значимые, но всё ещё важные признаки: форма и размер. Таким образом, каждый уровень правил реализует как бы свой «этаж принятия решений», где отбраковка или продвижение плода происходит пошагово, в зависимости от качества входных сигналов.

Иерархическая структура логического вывода представляется в виде:

1. Приоритет 1. Высокая степень повреждения

Если "D" = "высокий", то $\rightarrow$ «утиль». Это правило исключает все другие параметры из рассмотрения, поскольку сильное повреждение делает плод непригодным к использованию в любом виде.

2. Приоритет 2. Несоответствие цвета при малом или среднем повреждении

Если "D" $\in$ {малый, средний} и "C" = "не соответствует", то $\rightarrow$ «корм животным». Такая логика обусловлена снижением потребительской привлекательности даже при удовлетворительном физическом состоянии.

3. Приоритет 3. Небольшой размер при допустимых отклонениях формы и цвета

Если “D” ∈ {малый, средний}, “C” ∈ {соответствует, пограничное}, “F” ∈ {средняя, эллипсоидная}, “S” = “малый”, то → «пюре».

Мелкие плоды с допустимыми признаками направляются в производство пюре – как форма минимизации потерь.

4. Приоритет 4. Умеренное отклонение формы и/или размера при допустимых повреждениях

Если “D” ∈ {малый, средний}, “C” ∈ {соответствует, пограничное}, “F” ∈ {средняя, эллипсоидная}, S ∈ {средний, большой}, то → «сок». Это правило допускает отклонения, если плод пригоден для переработки.

5. Приоритет 5. Оптимальное состояние (продажа/хранение)

Если “D” ∈ {малый, средний}, “C” ∈ {соответствует, пограничное}, “F” = “сферическая”, то → «продажа» или «хранение». Здесь ключевыми являются визуальные и геометрические параметры, отражающие стандарты товарного вида.

Подобная иерархизация особенно важна при высоком темпе сортировки, например, более 3–5 плодов в секунду, где время обработки критично. К тому же, такая структура позволяет легко расширять систему. Добавление новых правил не нарушает уже отлаженный логический скелет, а просто встраивается в соответствующий уровень.

Таблица 2.2. База правил для нечеткой логики

№	Степень повреждени	Цвет (C)	Форма (F)	Размер (S)	Назначение	Q
1	Высокая	-	-	-	Утиль	0.12
2	Малая или средняя	Не соответствует	-	-	Корм животным	0.34
3	Средняя	Соответствует или пограничный	Средняя или эллипсоидная	Малый	Пюре	0.52
4	Малая или средняя	Соответствует или пограничный	Средняя или эллипсоидная	Средний или крупный	Сок	0.72
5	Малая	Соответствует или пограничный	Сферическая	-	Продажа / хранение	0.92

В Таблице 2.2 представлены описания правил нечёткой системы, отражающие принятые в ней логические соотношения. Каждому правилу

присвоено конкретное значение выходной переменной $Q \in [0;1]$, соответствующее одной из пяти категорий назначения плода: утиль, корм животным, пюре, сок, хранение/продажа. Значения Q были подобраны эмпирически, исходя из границ, установленных на этапе дефаззификации. Такая подача позволяет не только улучшить производительность системы, но и даёт возможность снижению потребляемых вычислительных ресурсов на этапе внедрения в производственную линию.

Финальным этапом работы нечёткой экспертной системы является дефаззификация – процедура преобразования нечетких, размазанных по значению выходных решений в одно конкретное числовое значение, пригодное для управляющего сигнала. В рассматриваемой архитектуре была выбрана модель Сугено нулевого порядка, где каждое правило возвращает фиксированную скалярную величину Q , характеризующую уровень пригодности плода. Именно поэтому в данной системе дефаззификация приобретает простой и в то же время формально строгий вид, основанный на взвешенном суммировании активированных правил.

Идея заключается в следующем: каждый активированный вывод из базы правил вносит вклад в общее решение пропорционально своей степени активации. Если обозначить d_i через достоверность (степень истинности) i -го правила, а через Q_i – его фиксированное выходное значение, то итоговая оценка $Q_{\text{итог}}$ рассчитывается по формуле:

$$Q_{\text{итог}} = \frac{\sum_{i=1}^n d_i \cdot Q_i}{\sum_{i=1}^n d_i} \quad (2.28)$$

Здесь n – число сработавших правил. Если сработало только одно правило, как это часто бывает в приоритетной (иерархической) системе, то итоговое значение совпадает с выходом этого правила, и формула сводится к простому $Q_{\text{итог}} = Q_i$.

Важным этапом после расчёта Q является его интерпретация – привязка полученного значения к конкретной категории решения. Для этого в системе

задана шкала интервалов, связывающих числовой выход с конкретным назначением плода:

- $Q \in [0,00; 0,24] \rightarrow$ **Утиль** (абсолютно непригодные плоды);
- $Q \in [0,24; 0,44] \rightarrow$ **Корм животным** (грубая переработка);
- $Q \in [0,44; 0,60] \rightarrow$ **Пюре** (условно пригодные плоды);
- $Q \in [0,60; 0,84] \rightarrow$ **Сок** (качественные, но не товарные);
- $Q \in [0,84; 1,00] \rightarrow$ **Продажа / хранение** (товарный продукт).

Эти интервалы были определены на основе анализа экспертных оценок, пробных сортировок и допустимых уровней дефекта, выявленных нейросетью. Они представляют собой логически упорядоченную шкалу технологической ценности плода и позволяют системе принимать формализованные, прозрачные и однозначные решения в потоке.

Полученное значение Q после интерпретации преобразуется в управляющий сигнал, который направляется на исполнительный механизм сортировочной линии. Таким образом, блок дефаззификации является связующим звеном между логическим ядром системы и физическим оборудованием. Его надёжность и корректность критически важны для всей интеллектуальной архитектуры, так как именно здесь окончательно определяется судьба каждого плода.

Отдельным достоинством выбранной модели является возможность адаптации шкалы Q под конкретные производственные условия: при необходимости можно сдвинуть порог «Сок/Хранение» или расширить диапазон «Пюре» в зависимости от требований заказчика, сезона, сорта и других факторов. Таким образом, блок дефаззификации делает систему по-настоящему гибкой и настраиваемой.

Для демонстрации функционирования разработанной нечёткой системы логического вывода рассмотрим конкретный пример прохождения реальных данных через все этапы обработки: от фаззификации до принятия окончательного решения. Такой подход позволяет наглядно проследить, как система интерпретирует входную информацию и с каким уровнем

достоверности активирует соответствующие правила, приводя в итоге к единственному управляющему действию.

В качестве примера рассмотрим следующий случай. Пусть камера зафиксировала плод со следующими характеристиками: степень повреждения $D = 0,35$, цветовое отклонение $RN = 0,16$, отношение диаметров $RD = 0,85$, а поперечный диаметр – 72 мм, что соответствует нормированному значению $SN = 0,44$. Каждая из этих величин подвергается фаззификации, то есть преобразуется в набор степеней принадлежности к термам соответствующих лингвистических переменных. Для D наибольшую активность проявляют термы «Средний» $\mu_{\text{ср}}(0,35) = 1,0$ и «Высокий» $\mu_{\text{выс}}(0,35) = 0,25$; для цвета – «Пограничный» $\mu_{\text{погр}}(0,16) = 0,6$ и «Соответствующий» $\mu_{\text{соотв}}(0,16) = 0,4$; для формы – оба терма «Сферическая» $\mu_{\text{сф}}(0,85) = 0,5$ и «Средняя» $\mu_{\text{ср}}(0,85) = 0,5$; по размеру значимо выражен только терм «Средний» $\mu_{\text{ср}}(0,44) = 0,84$.

На основании этих степеней принадлежности система производит сопоставление с базой правил. В данном случае из всех возможных активируется только правило №4 (таблица 2.2): если плод имеет малую или среднюю степень повреждения, пограничное или соответствующее цветовое соответствие, форму, близкую к стандартной, и средний размер, то он направляется на производство сока. Поскольку все условия этого правила удовлетворяются на частичных уровнях, система определяет его достоверность активации как минимум среди максимумов по каждому параметру:

$$d_4 = \min \left(\max(\mu_{\text{мал}}, \mu_{\text{ср}}), \max(\mu_{\text{соотв}}, \mu_{\text{погр}}), \max(\mu_{\text{сф}}, \mu_{\text{ср}}), \max(\mu_{\text{ср}}, \mu_{\text{круп}}) \right) \quad (2.29)$$

Подставляя значения:

$$d_4 = \min(1.0, 0.6, 0.5, 0.84) = 0.5$$

Переход к выходному значению осуществляется по механизму дефаззификации, принятым в системе Сугено – через взвешенное усреднение выходов сработавших правил:

$$Q_{\text{итог}} = \frac{\sum d_i \cdot Q_i}{\sum d_i} \quad (2.30)$$

Поскольку активировано только одно правило №4 с учетом (2.28), итоговое значение $Q_{\text{итог}}$:

$$Q_{\text{итог}} = \frac{0.5 \cdot 0.72}{0.5} = 0.72 \quad (2.31)$$

Согласно (2.31), это значение однозначно соответствует категории «Сок». Таким образом, плод будет направлен на соответствующую ветку сортировочной линии. Данный пример не только иллюстрирует корректность логики, но и подчёркивает прозрачность принятия решения: на каждом этапе сохраняется возможность интерпретации и аудита, что критически важно при внедрении интеллектуальных систем в производственные процессы.

2.5 Выводы по второй главе

В рамках второй главы был разработан и исследован комплекс теоретических предпосылок для реализации алгоритма косвенной оценки качества яблок при автоматизированной сортировке.

Разработана обобщенная схема алгоритма управления автоматизированной сортировкой с использованием нотации BPMN, обеспечивающая четкое описание последовательности операций, ветвлений и взаимодействий между модулями системы. Предложенная схема позволяет визуализировать и оптимизировать процесс сортировки, учитывая широкий спектр параметров и ограничений.

Разработана математическая модель, связывающая площадь повреждения плода с его предполагаемым объемом. Установлено, что аппроксимация плода сферой, а повреждения – средним между полусферой и сектором, позволяет получить адекватную оценку объема повреждения на основе площади дефекта. Проведенное сравнение с эмпирическими данными показало, что предложенная модель обеспечивает точность оценки объема

повреждения с отклонением не более 15% при условии, что относительная площадь повреждения kS не превышает 25.

Реализован алгоритм косвенной оценки объема повреждения плодов, визуализированный в нотации BPMN, позволяющий на основе анализа изображений и применения разработанной математической модели определять объем поврежденной ткани плода.

Разработана модель нечеткой логики с приоритетной иерархией принятия решений для классификации яблок по категориям качества. Определены лингвистические переменные и построены соответствующие функции принадлежности. Реализована процедура дефаззификации на основе модели Сугено нулевого порядка, обеспечивающая преобразование нечетких выходных значений в конкретные управляющие сигналы для системы сортировки. Проведенный анализ на примере реальных данных показал адекватность работы системы нечеткой логики, что подтверждается соответствием полученных выходных значений итоговым решениям об отнесении плодов к определенной категории качества.

3. ПРОГРАММНАЯ РЕАЛИЗАЦИЯ ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ СОРТИРОВКИ ПЛОДОВ

3.1 Постановка задач

Разработка и внедрение комплексных алгоритмов анализа визуальной информации и принятия решений на основе искусственного интеллекта требует программной реализации автоматизированной системы сортировки яблок. Программное обеспечение является ключевым звеном, обеспечивающим взаимодействие между аппаратной частью системы и алгоритмами обработки данных, что в конечном итоге позволяет реализовать эффективные алгоритмы управления сортировочным процессом.

Реализация данных алгоритмов в программной среде обеспечивает автоматизированное и точное определение качества плодов, что снижает влияние субъективного фактора и повышает производительность. Кроме того, интеграция нейронных сетей и систем отслеживания объектов в единую систему позволяет осуществлять динамический контроль и корректировку процесса сортировки в реальном времени. Важным аспектом является также обеспечение надежной и своевременной передачи информации на программируемый логический контроллер, что позволяет осуществлять прямое управление исполнительными механизмами сортировочного оборудования.

Для создания полнофункциональной интеллектуальной системы, способной обеспечить высокое качество и стабильность производственной процесса необходимо решение следующих задач:

1. Привести подходы к реализации подзадач разработанной обобщенной схемы алгоритма автоматизированной сортировки яблок;
2. Провести выбор архитектуры сверточной нейронной сети, выполнить ее обучение на специализированном наборе данных и провести оценку качества классификации;

3. Создать систему отслеживания и сохранения идентификации объектов в видеопотоке, обеспечивающую устойчивое распознавание и мониторинг каждого плода в режиме реального времени.

4. Реализовать механизм передачи обработанных данных и управляющих сигналов на программируемый логический контроллер для организации автоматического управления сортировочным оборудованием и обеспечения синхронизации всех компонентов системы.

3.2 Реализация подзадач алгоритма автоматизированной сортировки яблок

Основные этапы реализации разработанного алгоритма автоматизированной оценки качества плодов и их сортировки, представленные на обобщенной схеме BPMN диаграммы (рис. 2.1), требуют подробного описания каждой подзадачи. Такой подход позволяет не только четко структурировать материал, но и раскрыть суть технических решений в основе разработки [141, 142, 143].

Подробное описание каждой подзадачи способствует формированию целостного представления о работе системы, демонстрируя, как отдельные функциональные блоки взаимосвязаны и взаимодействуют друг с другом. Это особенно важно в контексте сложных интеллектуальных систем, где отлаженная последовательность этапов обработки данных является ключом к достижению высокой точности и надежности работы.

Высокий уровень детализации также обеспечивает воспроизводимость результатов исследования. В научной работе крайне важно, чтобы другие специалисты могли повторить эксперименты, проверить корректность полученных данных и на их основе развивать и совершенствовать существующие подходы. Подробное описание алгоритмов и архитектуры системы создает необходимые условия для дальнейшей интеграции и масштабирования разработанных решений.

3.2.1 Инициализация аппаратной платформы

Процесс инициализации аппаратной платформы представляет собой один из ключевых этапов подготовки интеллектуальной системы к функционированию в условиях реального производственного процесса сортировки яблок. Основной задачей этого этапа является обеспечение стабильной, корректной и синхронизированной работы всех компонентов аппаратного комплекса, включая систему технического зрения и элементы механической транспортировки [144, 145].

Инициализация начинается с настройки камеры, которая играет фундаментальную роль в обеспечении качества захвата изображений. На данном этапе требуется выбрать оптимальное разрешение камеры, что является компромиссом между детальностью изображения и скоростью обработки данных.

Настройка частоты кадров камеры, параметр определяет, насколько часто система будет получать новые изображения для анализа. Здесь учитывается скорость движения конвейерной ленты для обеспечения такого обновления изображений, при котором яблоки успевают фиксироваться с минимальными перекрытиями и без пропусков.




Рис. 3.1. Инициализация аппаратной платформы

Использование светодиодных модулей с возможностью программной регулировки яркости позволяет динамически адаптировать освещение под

различные внешние условия, такие как уровень естественного света в производственном помещении, минимизируя тени и блики на поверхности плодов. Регулировка интенсивности света может проводиться с использованием программного модуля калибровки освещения, позволяющего задавать целевые параметры яркости в реальном времени [146].

Для оценки однородности используется тестовый шаблон – равномерная матовая поверхность, позволяющая объективно измерить распределение яркости по всему полю зрения камеры. В случае обнаружения отклонений более 5% от среднего уровня освещения требуется перенастройка системы осветителей и положения камеры.

Процесс калибровки системы (рис. 3.1) включает в себя коррекцию геометрических искажений, вызванных оптическими особенностями объектива камеры, а также настройку внутренней синхронизации всех модулей технического зрения.

3.2.2 Захват и сохранение изображений плодов

Основной целью подзадачи «Захвата и сохранения изображений плодов» (рис 2.1), является получение качественных изображений плодов с различных ракурсов, что необходимо для обеспечения полноты данных при последующем анализе повреждений и дефектов (рис. 3.2).




Рис. 3.2. Подзадача «Захвата и сохранения изображений плода»

Здесь осуществляется контроль ориентации плода на транспортной ленте. Учитывая природную неоднородность формы яблок и их возможную неправильную ориентацию при подаче, крайне важно обеспечить такое положение объекта относительно камеры, при котором будет минимизирована вероятность перекрытия дефектов или их скрытия тенями. Наилучший баланс между эффективностью и сложностью реализации достигается применением специального материала поверхности транспортёра, способствующего мягкой прокатке плодов под действием собственной массы и перемещающего момента [147, 148].

Обеспечение многократной съёмки плодов под разными углами особенно важен, поскольку отдельное изображение не способно отразить всю поверхность плода, а дефекты могут находиться на противоположной от камеры стороне. Организация пассивной прокатки плодов на транспортере позволяет существенно упростить конструкцию при сохранении высокой полноты обзора. Исследования показали, что съёмка трёх–четырёх изображений плода на протяжении его движения по контрольной зоне даёт достаточное покрытие поверхности при минимальных ресурсных затратах. Фрагмент кода, реализующего алгоритм запуска захвата изображения представлен в приложении 2.

После выполнения съёмки полученные изображения сохраняются в буфер обмена или напрямую на локальный диск системы. Этот подход обеспечивает дополнительную надёжность, так как в случае возникновения ошибок в последующих этапах обработки всегда имеется возможность повторной загрузки исходных изображений без необходимости повторного захвата. Результат работы алгоритма запуска захвата изображения представлен на рис. 3.3.

Изображения, подготовленные на данном этапе, проходят предварительную верификацию, включающую контроль целостности файлов, проверку соответствия формата и размеров изображения требованиям системы последующей обработки [150, 153].

```

Обнаружен новый плод: fruit_102
Изображение первый ракурс для плода fruit_102 захвачено
Изображение второй ракурс для плода fruit_102 захвачено
Изображение третий ракурс для плода fruit_102 захвачено
Сохранение изображений для плода fruit_102: ['первый ракурс', 'второй ракурс', 'третий ракурс']
Переход к следующему плоду

Обнаружен новый плод: fruit_103
Изображение первый ракурс для плода fruit_103 захвачено
Изображение второй ракурс для плода fruit_103 захвачено
Изображение третий ракурс для плода fruit_103 захвачено
Сохранение изображений для плода fruit_103: ['первый ракурс', 'второй ракурс', 'третий ракурс']
Переход к следующему плоду

Обнаружен новый плод: fruit_104
Изображение первый ракурс для плода fruit_104 захвачено
Изображение второй ракурс для плода fruit_104 захвачено
Изображение третий ракурс для плода fruit_104 захвачено
Сохранение изображений для плода fruit_104: ['первый ракурс', 'второй ракурс', 'третий ракурс']
Переход к следующему плоду

Обнаружен новый плод: fruit_105
Изображение первый ракурс для плода fruit_105 захвачено
Изображение второй ракурс для плода fruit_105 захвачено
Изображение третий ракурс для плода fruit_105 захвачено
Сохранение изображений для плода fruit_105: ['первый ракурс', 'второй ракурс', 'третий ракурс']
Переход к следующему плоду

```

Рис. 3.3. Результаты работы алгоритма запуска захвата изображения

Таким образом, этап захвата и сохранения изображений плодов представляет собой важное звено технологической цепочки интеллектуальной системы сортировки, обеспечивая получение высококачественных данных для дальнейшего анализа состояния плодов.

3.2.3 Передача данных в модуль предобработки

На следующем этапе технологического процесса осуществляется передача данных в модуль предобработки изображений. На рисунке 3.4 представлена схема данного процесса, отражающая последовательные этапы структурирования информации перед дальнейшей обработкой.

Процесс передачи данных начинается с формирования организованного потока изображений. Его основная задача заключается не только в упорядочении файлов, но и в обеспечении их сопровождения всей необходимой метаданной, что критически важно для поддержания целостности данных на последующих этапах обработки. На этапе проектирования рассматривались различные архитектуры организации потоков: как с использованием отдельных баз данных для метаданных, так и с

встраиванием информации непосредственно в структуру файлов. В результате анализа преимуществ и недостатков различных подходов было выбрано решение о прямом объединении изображения и его атрибутов в единый поток данных.




Рис. 3.4. Подзадача «Передачи данных в модуль предобработки»

Идентификация партии позволяет осуществлять отслеживание происхождения партии в рамках производственного цикла и обеспечивает возможность оперативного реагирования в случае выявления дефектных серий продукции. Для реализации идентификации применяется кодирование уникального идентификатора партии, формируемого на основе времени начала обработки партии и её производственного индекса [154, 155, 156].

Идентификация координат плода на ленте осуществляется на основе данных, получаемых от системы энкодеров, установленных на транспортной линии. Координаты позволяют отслеживать точное положение каждого плода в момент съёмки, что существенно повышает точность при последующей локализации дефектов на изображениях. В качестве альтернативы рассматривалась возможность применения систем трекинга на основе машинного зрения, однако данный подход был признан избыточным по сложности для задач данного уровня.

Идентификация времени съёмки представляет собой обязательный этап, обеспечивающий временную привязку каждого изображения. Модуль регистрации времени синхронизирован с системными часами аппаратной платформы, что гарантирует высокую точность фиксации момента получения

изображения, вплоть до миллисекундного разрешения. Эти данные впоследствии используются для анализа производительности системы, выявления возможных сбоев и оптимизации работы всей сортировочной линии.

После формирования полной структуры метаданных осуществляется передача изображений и сопровождающей информации в модуль предобработки. На данном этапе данные поступают в систему, предназначенную для проведения первичной фильтрации, нормализации и подготовки изображений к последующему этапу нейросетевого анализа.

3.2.4 Проверка качества входных данных

На этапе проверки качества входных данных осуществляется критическая оценка состояния изображений, направленных в модуль предобработки [41, 43, 45].

Процесс начинается с анализа метаданных изображений (рис. 3.5). На данном этапе система извлекает служебную информацию, сопровождающую каждый файл, такую как разрешение, параметры освещённости и характеристики съёмки. Проверка метаданных позволяет ещё до непосредственного анализа визуального содержимого выявить очевидные отклонения от установленных стандартов, что повышает общую эффективность процесса фильтрации.




Рис. 3.5. Схема проверки качества входных данных

Для обеспечения объективности оценки используется набор эталонных изображений, сформированных на этапе калибровки системы. Эти эталоны включают в себя допустимые диапазоны разрешения, резкости и яркости, характерные для корректно снятых образцов.

Анализ изображений проводится по трём основным критериям. Первым параметром оценки является разрешение кадра. Изображения, разрешение которых выходит за пределы допустимого диапазона, автоматически отбраковываются. Эта мера позволяет исключить файлы, полученные вследствие сбоя камеры или ошибок конфигурации съёмки [49, 52, 58].

Далее осуществляется проверка резкости изображения. Для этого применяется сравнительный анализ по метрике резкости, сопоставляемой с эталонным значением. Кадры с признаками сильного размытия или некорректной фокусировки исключаются из дальнейшего процесса обработки.

Третьим критерием служит анализ яркости. Изображения с недостаточной или избыточной освещённостью, выходящей за установленные пороговые значения, также подлежат отбраковке. Проблемы с яркостью могут приводить к ошибкам сегментации и ложной классификации дефектов, поэтому данный параметр контроля является обязательным.

После проведения всех этапов проверки изображения, удовлетворяющие всем критериям качества, передаются на следующий этап обработки. Отбракованные файлы исключаются из потока и фиксируются в системе логирования для последующего анализа причин возникновения дефектов.

3.2.5 Коррекция и фильтрация изображения

На этапе коррекции и фильтрации изображений осуществляется подготовка визуальных данных к последующей глубокой обработке, включая сегментацию дефектов и классификацию состояния плодов. Схема процесса представлена на рисунке 3.6 и отражает последовательные методы, направленные на повышение качества изображений.

Первоначально применяется метод выравнивания гистограммы яркости, целью которого является устранение нерегулярностей в распределении освещения на изображении. Из-за особенностей реальных условий съёмки, таких как неравномерность искусственного освещения или наличие частичных теней, исходные изображения могут обладать значительными вариациями яркости. Выравнивание гистограммы позволяет перераспределить интенсивность пикселей, тем самым улучшая контрастность изображения и облегчая последующую задачу выделения дефектных областей. Для коррекции были рассмотрены различные алгоритмы, включая CLAHE (Contrast Limited Adaptive Histogram Equalization), который был выбран за способность избегать чрезмерного усиления шума в тёмных зонах.




Рис. 3.6. Подзадача «Коррекция и фильтрации изображения»

Наличие мелких случайных вариаций яркости и цвета, способно негативно влиять на работу алгоритмов сегментации. Для устранения шумов применяются методы фильтрации, такие как медианный фильтр и гауссово размытие. В процессе тестирования медианный фильтр показал наилучший баланс между подавлением шумов и сохранением границ объектов, что

критически важно для корректной локализации дефектов на поверхности плодов [40, 42, 44].

Отдельное внимание уделяется устранению бликов, возникающих в результате отражения света от глянцевой поверхности яблок. Блики могут маскировать дефекты или, напротив, имитировать их наличие, что приводит к ложным срабатываниям на этапе анализа. Для борьбы с этим эффектом применяются методы локальной коррекции интенсивности, основанные на выделении участков изображения с аномально высокой яркостью и их адаптивной коррекции. В качестве альтернативы рассматривалась поляризационная съёмка для снижения бликов на этапе получения изображений, однако её внедрение потребовало бы существенных изменений аппаратной части комплекса, что сделало программную коррекцию более предпочтительной [46, 85, 86].

Все методы коррекции и фильтрации реализованы таким образом, чтобы минимально искажать структуру изображения и сохранять естественные особенности поверхности плодов, что особенно важно для последующего нейросетевого анализа.

Таким образом, реализованный комплекс методов коррекции и фильтрации изображений обеспечивает базовую очистку и стандартизацию входных данных, создавая надёжную основу для высокой точности дальнейших этапов интеллектуальной обработки.

3.2.6 Нормализация цвета и выделение контуров плода

На этапе нормализации цвета и выделения контуров плода осуществляется первичная подготовка изображений к локализации дефектных областей. Этот процесс направлен на повышение контрастности целевых признаков относительно фона и оптимизацию последующего анализа (рис. 3.7).

Изначально производится преобразование цветовой модели изображения из стандартного пространства *RGB* в пространство *HSV* (Hue, Saturation, Value).




Рис. 3.7. Схема нормализации цвета и выделения контуров плода

Данный переход обусловлен тем, что в пространстве *HSV* цветовой тон, насыщенность и яркость разделены на независимые компоненты, что значительно облегчает выделение дефектных участков плода. Использование пространства *HSV* позволяет минимизировать влияние вариаций освещенности и более точно настраивать алгоритмы выделения признаков. Фрагмент кода, реализующий преобразование цветовой модели и поиски контура представлены в приложении 3.

Далее выделяются границы плода, для этого используется анализ каналов *HSV* и применение методов поиска контуров. На практике реализована последовательность операций:

- предварительное выделение плода на фоне путём пороговой обработки одного из каналов;
- фильтрация мелких шумов и выделение замкнутого контура объекта.

Предпочтение было отдано детектору контуров на основе алгоритма поиска внешних границ, что позволило добиться высокой устойчивости результатов при наличии фоновых артефактов (рис. 3.8).



Рис. 3.8 Результат преобразования цветовой модели и поиска контура

Координаты выделенного контура фиксируются и сохраняются для дальнейшего использования при локализации дефектных участков и расчёте метрик повреждения. Сохранение точной формы плода на данном этапе является принципиально важным, так как ошибки в выделении контура могут привести к снижению точности всей последующей обработки.

3.2.7 Формирование набора предобработанных изображений

Формирование набора предобработанных изображений завершает стадию подготовки данных для нейросетевого анализа. На рисунке 3.9 представлена схема данного процесса, отражающая ключевые операции сохранения и организации данных [93, 95, 101].

В первую очередь производится сохранение предобработанных изображений и сопутствующих метаданных во временное хранилище, использующее локальную файловую систему с организованной структурой каталогов по идентификаторам партий и номерам плодов.

После сохранения данные подготавливаются к передаче в очередь обработки нейронной сетью. Этот этап включает выборку только тех изображений, которые успешно прошли этапы коррекции, фильтрации и проверки качества, а также дополнение соответствующими метками

координат границ плода. Формирование очереди обеспечивает правильную последовательность подачи изображений в модуль нейронного анализа, минимизируя задержки и оптимизируя загрузку вычислительных ресурсов.




Рис. 3.9. Схема формирования набора предобработанных изображений

Таким образом, этап формирования набора предобработанных изображений выполняет функцию промежуточного звена между процессами подготовки изображений и их интеллектуального анализа, обеспечивая надёжность, структурированность и согласованность всех поступающих в обработку данных.

3.2.8 Инициализация и загрузка сверточной нейронной сети

В целях обеспечения целостного восприятия и логической последовательности изложения, в первую очередь будет представлен полный алгоритм косвенной оценки объема повреждения плодов, включающий все этапы обработки и анализа данных. После создания общего представления о структуре и функционировании системы, внимание будет уделено подробному рассмотрению сверточной нейронной сети (п.п. 3.3), важного компонента, отвечающего за выделение и классификацию поврежденных областей. Такой подход позволяет не только понять роль нейросети в рамках общей архитектуры, но и обосновать выбор методов ее разработки и обучения на основе требований, вытекающих из поставленной задачи [5, 7, 66].

Поэтому рассмотрим инициализацию и загрузку модели сверточной нейронной сети (СНС), которая является ответственным этапом подготовки

интеллектуальной системы к проведению анализа изображений плодов (рис. 3.10).

Инициализация начинается с подключения заранее обученной модели СНС. Для этого загружаются два типа файлов: файл весов модели в формате *.h5* и файл описания архитектуры в формате *.json*. Разделение структуры и параметров модели позволяет существенно ускорить процесс загрузки и повысить гибкость эксплуатации различных вариантов нейросетевых конфигураций. Использование формата *.json* обеспечивает удобство документирования архитектуры сети и её верификацию перед загрузкой весов, а формат *.h5*, принятый в библиотеке *HDF5*, позволяет эффективно хранить большие объёмы числовых данных.




Рис. 3.10. Схема инициализации и загрузки модели сверточной нейронной сети

В качестве основной платформы для загрузки и работы модели используется библиотека TensorFlow/Keras, которая была выбрана благодаря своей высокой стабильности, широкой поддержке современных архитектур сетей и удобным средствам интеграции с промышленными решениями. Фрагмент кода для подключения СНС и установки порога доверия представлен в приложении 4.

После загрузки модели производится её подключение к системе обработки изображений. На данном этапе выполняется проверка корректности

структуры сети, включая соответствие входного размера данных и числа выходных классов предполагаемым стандартам обработки дефектов плодов. В случае расхождений осуществляется автоматическая адаптация структуры модели либо выбрасывается ошибка для предотвращения некорректной работы [8, 13, 15].

3.2.9 Выделение области повреждения

На этапе выделения области повреждения осуществляется непосредственный анализ изображений, направленный на локализацию дефектных участков плода (рис. 3.11)

Процесс начинается с запуска процедуры сегментации на предобработанных изображениях. Для выполнения этой задачи используется ранее загруженная модель сверточной нейронной сети, обученная на специальной выборке изображений с маркировкой дефектных областей. Модель принимает на вход нормализованные изображения и формирует выходные карты вероятностей, каждая точка которых отражает вероятность принадлежности данного пикселя к классу повреждения. Фрагмент кода для сегментации повреждений и выделения области повреждения приведен в приложении 5.




Рис. 3.11. Схема выделения области повреждения

На следующем этапе проводится проверка результатов сегментации на наличие повреждений. Для этого применяется установленный ранее порог доверия: участки изображения, для которых вероятность дефекта превышает заданное значение, считаются повреждёнными. Если повреждение обнаружено, система переходит к формированию маски дефектной области (рис. 3.12)



Рис. 3.12. Результат определения области повреждения плода

В случае отсутствия обнаруженного повреждения процесс обработки для данного плода завершается, и система переходит к анализу следующего объекта. Данный механизм позволяет существенно повысить производительность всей сортировочной линии за счёт исключения лишних этапов анализа для неповреждённых плодов [16, 17, 47].

3.2.10 Подзадачи «Определения площади и объема повреждения плодов» и «Агрегации и верификации результатов»

Этап определения площади и объема повреждения плода является центральным компонентом интеллектуальной системы оценки состояния продукции. Именно на этом этапе производится количественная характеристика повреждений, что обеспечивает основу для принятия решений

в системе сортировки. Подробно разработка и визуализация алгоритма в виде BPMN диаграммы (рис. 2.5) представлены в п.п. 2.3.




Рис. 3.13. Пример работы сверточной нейронной сети для выявления поврежденных плодов

Нейросеть обеспечивает автоматическое выделение дефектных зон и формирование соответствующих масок, что значительно повышает скорость и достоверность последующего анализа. Пример работы сверточной нейронной сети представлен на рисунке 3.13, где показан процесс детектирования поврежденных плодов на движущейся конвейерной ленте. Использование методов глубокого обучения позволило минимизировать количество ложных классификаций и улучшить качество оценки степени повреждения продукции.

Разработанный алгоритм, сочетающий классические геометрические методы и современные нейросетевые подходы, позволяет комплексно оценивать степень повреждения плодов. Применение двойного критерия – по площади и объему повреждений – значительно повышает достоверность классификации и дает возможность ранжировать продукцию по степеням повреждения. Это, в свою очередь, позволяет оптимизировать сортировочные

процессы, повысить качество готовой продукции и сократить потери на этапе переработки. Подзадача «Агрегация и верификация» рассмотрена на рис. 3.14 и в п.п. 2.4.



Рис. 3.14. Схема агрегации и верификации результатов

3.2.11 Сохранение в базе данных

После проведения агрегации и верификации данных система переходит к этапу сохранения информации в базе данных. Этот процесс необходим для обеспечения последующего анализа, отслеживания качества продукции, а также для формирования отчетности и принятия управленческих решений (рис. 3.15).

На первом этапе осуществляется запись результатов обработки, включающих значения k_S и k_V , в базу данных. Для обеспечения целостности данных используется транзакционная модель записи, что предотвращает появление неконсистентных или частичных записей даже в случае сбоев в работе системы [48, 50, 51].



Рис. 3.15. Схема сохранения результатов в базе данных

Запись данных сопровождается привязкой к уникальному идентификатору конкретного плода или партии продукции. Идентификатор может быть сформирован автоматически на этапе регистрации партии или сгенерирован на основе метаданных, полученных в процессе сканирования (например, с использованием временных меток или координат положения на конвейере). Такая система идентификации обеспечивает возможность точного отслеживания каждого объекта на всех этапах производственного процесса.

База данных организована с использованием структуры, оптимизированной для хранения результатов технического зрения и анализа дефектов. Для каждого плода сохраняется набор параметров, включающий геометрические характеристики, результаты анализа повреждений, результаты классификации по качеству, а также дополнительную сопутствующую информацию, например, принадлежность к партии, условия хранения и обработки [20, 23, 96].

Данные обработки сохраняются в реляционной базе данных по нормализованной схеме, позволяющей реконструировать полный путь принятия решения. Фрагменты ER-диаграммы и листинг SQL-скрипта для воспроизводимого развертывания схемы приведены в приложении 6.

3.2.12 Формирование выходных отчетов и визуализация данных

На заключительном этапе работы системы производится формирование выходных отчетов и визуализация данных, что позволяет не только оперативно управлять процессом сортировки, но и анализировать эффективность функционирования системы (рис. 3.16)

Процесс начинается с подачи управляющего сигнала на автоматизированную систему сортировки. На основе ранее рассчитанных показателей повреждения плодов (k_S и k_V), а также сопоставления этих данных с внутренними пороговыми значениями, принимается решение о направлении каждого плода. Если степень повреждения превышает установленные допустимые пределы, формируется сигнал на удаление плода в канал

утилизации. В противном случае плод поступает на дальнейшую сортировку в соответствии с его качественными характеристиками.




Рис. 3.16. Подзадача «Формирование выходных отчетов и визуализация»

Процесс начинается с подачи управляющего сигнала на автоматизированную систему сортировки. На основе ранее рассчитанных показателей повреждения плодов k_S и k_V , а также сопоставления этих данных с внутренними пороговыми значениями, принимается решение о направлении каждого плода. Если степень повреждения превышает установленные допустимые пределы, формируется сигнал на удаление плода в канал утилизации. В противном случае плод поступает на дальнейшую сортировку в соответствии с его качественными характеристиками [97, 98, 99].

Пороговые значения определяются в зависимости от предварительно проведенного анализа экспериментальных данных, что позволяет учесть особенности конкретного сорта продукции, сезонные колебания качества и требования стандартизации. Механизм передачи управляющего сигнала интегрирован с исполнительными модулями сортировочной линии, что обеспечивает минимальные задержки между принятием решения и выполнением действия.

Параллельно с процессом принятия решений о маршрутизации плодов осуществляется генерация сводных таблиц степени повреждения. Эти таблицы содержат детальную информацию о каждом плоде: уникальный идентификатор, рассчитанные параметры повреждения, категорию

назначения, а также дополнительные диагностические показатели, такие как тип повреждения, площадь и объем поражения. Формирование таблиц позволяет организовать системный сбор данных для последующего статистического анализа, оптимизации пороговых значений и корректировки алгоритмов сортировки в реальном времени.

Формирования выходных отчетов и визуализации данных завершает цикл обработки информации в системе, обеспечивая обратную связь, возможность оперативной корректировки параметров работы и повышение общей эффективности сортировочного комплекса.

3.3 Модель сверточной нейронной сети для оценки повреждения плодов

3.3.1 Сбор и разметка данных для обучения модели

Задача отслеживания объекта с точным выделением его границ относится к классу задач сегментации отдельных экземпляров объектов на изображении. В отличие от детекторов, ограничивающих объект рамкой, сегментаторы восстанавливают его истинный контур, что критически важно в тех случаях, когда форма, площадь или степень слияния объекта с фоном существенно влияют на последующую обработку и принятие решений. Именно это требование стало ключевым при подготовке обучающего материала для сегментационной модели, предназначенной для трекинга яблок на конвейере [53, 54, 55].

Исходным источником данных стал как открытый датасет, так и видеопоток, записанный в условиях, имитирующих реальные производственные. Видеофайл был преобразован в последовательность кадров с оптимальным временным интервалом, исключая повторяющиеся или почти идентичные изображения. Отбор проводился с учетом максимального разнообразия сцен: менялись углы обзора, расстояния до камеры, фоновое окружение, степень перекрытия объектами и освещение. При этом из выборки исключались смазанные, засвеченные или

недоэкспонированные кадры, не несущие полезной информации для обучения.

Для повышения обобщающей способности модели применялись методы аугментации, затрагивающие как геометрию, так и фотометрию. Были реализованы отражения, случайные повороты, масштабирование, аффинные искажения, а также изменение яркости, контрастности, насыщенности и цветового оттенка. Добавлялись лёгкие шумы и размытия, имитирующие условия съёмки в нестабильной среде. Каждое преобразование применялось с определённой вероятностью, а изменения синхронизировались с масками. В результате набор данных расширился почти втрое, без потери достоверности контуров [56, 94, 100].

Анализ свойств обучающей выборки начинается с характеристики её объёма и состава. Всего было аннотировано порядка 2200 экземпляров класса «яблоко». Другие классы объектов в корпус не включались, что, с одной стороны, значительно упрощает процедуру обучения модели – отпадает необходимость в межклассовом разделении – однако, с другой стороны, ограничивает потенциал модели к масштабированию на мультиклассовые задачи или к дальнейшей адаптации на данные с отличной предметной структурой.

Распределение объектов по кадру обладает выраженной пространственной асимметрией. Гистограммы координат центров ограничивающих прямоугольников показывают плотную концентрацию значений в диапазоне от 0,4 до 0,6 по обоим осям – как горизонтальной (x), так и вертикальной (y). Таким образом, большая часть яблок расположена в центральной зоне изображения, формируя так называемую пространственную предвзятость. Это означает, что модель на этапе обучения приобретает склонность ожидать появления объектов в центре кадра.

В задачах свободной детекции такая особенность может привести к ложным срабатываниям или пропускам на периферии. Однако в нашем случае – при использовании стационарной камеры над транспортером и

центрированном положении плодов – подобная предвзятость не представляет проблемы и даже может быть интерпретирована как особенность рабочей сцены.




Рис. 3.17 Гистограммы координат экземпляров

Ширина и высота прямоугольных рамок находятся в практически линейной зависимости, что указывает на доминирование форм, близких к квадратным. На диаграмме рассеяния с наложенными гистограммами (рис. 3.17) отчётливо видно, что основные скопления точек соответствуют объектам малого и среднего размера. Преобладание таких размеров может быть связано как с особенностями конкретной партии продукции, так и с характеристиками камеры, установленной на экспериментальном стенде. Тем не менее, наличие экземпляров различных масштабов – от мелких до крупноформатных –

обеспечивает обучающей выборке необходимую вариативность и тем самым улучшает устойчивость модели к масштабным трансформациям.




Рис. 3.18 Матрица диаграмм рассеяния с гистограммами

На рисунке 3.17 представлены гистограммы распределения координат центров объектов, а рисунок 3.18 демонстрирует взаимосвязь размеров через матрицу диаграмм рассеяния с наложенными плотностями распределения.

3.3.2 Выбор и обоснование модели СНС для задачи оценки повреждений плодов

Важным этапом создания интеллектуальной автоматизированной системы является выбор и обоснование модели СНС. Проведя сравнительный анализ современных нейросетевых архитектур, пригодных для решения задачи сегментации и отслеживания яблок в видеопотоке. Основной целью анализа является выбор модели, обеспечивающей высокую точность выделения объектов на каждом кадре и устойчивый трекинг между кадрами,

при этом удовлетворяющей требованиям реального времени и пригодности для внедрения на встраиваемые устройства.

В обзор включены следующие архитектуры: YOLOv11-seg, Mask R-CNN, DeepLabv3+, SAM (Segment Anything Model) и Detectron2. Для каждой из них рассматриваются преимущества и ограничения с точки зрения следующих критериев: точность сегментации (включая метрики mAP и IoU), производительность инференса (FPS), наличие встроенной поддержки сегментации, возможность интеграции с трекерами, удобство внедрения (вес модели, требования к оборудованию) и открытость к дообучению.

YOLOv11-seg представляет собой развитие одноэтапных архитектур, ориентированных на высокоскоростную обработку изображений в реальном времени. Отличительной чертой данной модели является интеграция полноценной поддержки instance-сегментации, что позволяет не только обнаруживать объекты, но и точно восстанавливать их форму. Такое решение особенно актуально в задачах сортировки продукции, где важна не только локализация, но и корректное определение границ [102, 106, 108].

Высокая точность YOLOv11-seg в решении задач сегментации позволяет ее использовать в условиях сложного фона и частичных перекрытий. При этом большая скорость интерфейса позволяет обрабатывать изображения за 30-35мс.

Эти характеристики делают модель пригодной для обработки видеопотоков в реальном времени, что критически важно для сортировочных систем, и позволяет строить устойчивые треки движения объекта в кадре и между кадрами, что необходимо при реализации системы, контролирующей перемещение каждого яблока по всей траектории.

Открытость и поддержка промышленных стандартов модели CHS доступна для модификации и имеет подробную документацию, что упрощает процесс внедрения и адаптации.

Архитектура Mask R-CNN представляет собой классический двухэтапный подход к задаче сегментации. Основным достоинством данной

модели является высокая точность. При этом Mask R-CNN требует значительных вычислительных ресурсов и обладает низкой скоростью интерфейса.

К достоинствам DeepLabv3+ относится высокая точность сегментации на уровне пикселей, особенно в условиях сложного фона или освещения. Это позволяет использовать модель, например, для оценки площади плодов при агрономическом мониторинге или при задаче подсчёта урожайности. Дополнительным преимуществом является высокая проработка границ объектов [110, 118, 123].

Однако семантическая сегментация менее чувствительна к мелким объектам. При наличии большого количества небольших яблок на кадре модель может объединять близкие плоды в единую область или пропускать отдельные экземпляры. Это снижает её применимость в условиях, когда важно точно зафиксировать каждый плод.

При этом архитектура DeepLabv3+ не предусматривает встроенного трекинга и обрабатывает каждый кадр независимо. Отсутствие информации об экземплярах в выходной маске дополнительно усложняет интеграцию с трекерами.

Одним из ключевых достоинств SAM (Segment Anything Model) является её универсальность. Даже без специальной донастройки на тематические изображения, модель способна сегментировать яблоки, если пользователь укажет точку или рамку в соответствующей области. Это делает SAM привлекательным инструментом в ситуациях, когда система должна адаптироваться к разным типам объектов и сцен, не ограничиваясь строго специализированным применением.

Трансформерная архитектура позволяет учитывать мелкие контурные особенности, а масштабное обучение на разнообразных данных приближает точность модели к уровню ручной разметки. В задаче сегментации яблок это означает возможность выделения даже частично закрытых листьями или бликами плодов без значительной потери формы маски.

Тем не менее, имеются и существенные ограничения. Главным из них является высокая вычислительная нагрузка. Даже базовая версия SAM требует значительных ресурсов: модели занимают сотни мегабайт, а время инференса на CPU может достигать 49 секунд на изображение.

Кроме того, SAM не включает встроенного механизма трекинга. Каждый кадр обрабатывается отдельно, без присвоения идентификаторов и без учета временной связи между масками. Для применения в видеозадаче, такой как отслеживание движения яблок, потребуется внешний модуль сопоставления масок между кадрами, основанный, например, на пересечении областей, что усложняет архитектуру системы и замедляет её работу.

Detectron2 выгодно отличается высокой модулярностью. Архитектура модели и параметры обучения настраиваются с высокой гибкостью. Однако высокая ресурсоемкость, низкая скорость интерфейса и отсутствие встроенных алгоритмов трекинга ограничивают использование данной модели в задачах оценки качества плодов.

Учитывая результаты проведённого анализа, архитектура YOLOv11-seg представляется наилучшим выбором для решения задачи сегментации и трекинга яблок на видеопотоке, получаемом со стационарных камер. Такой выбор продиктован совокупностью факторов, обеспечивающих баланс между качеством предсказания, производительностью и практической реализуемостью в условиях ограниченных вычислительных ресурсов.

Во-первых, модель демонстрирует оптимальное соотношение точности и скорости. Благодаря архитектурным улучшениям, YOLOv11-seg обеспечивает высокую детальность масок и устойчивость к частичному перекрытию объектов, при этом сохраняя производительность в реальном времени даже на устройствах средней мощности. По сравнению с Mask R-CNN, требующей значительно больших ресурсов, YOLOv11-seg выигрывает за счёт одноэтапной структуры и эффективной обработки входных данных. Это особенно важно в полевых условиях, где каждый кадр должен

обрабатываться с минимальной задержкой, чтобы избежать пропусков и потери синхронизации при трекинге.

Во-вторых, модель изначально адаптирована под задачу многокадрового сопровождения объектов. В связке с трекером ByteTrack или DeepSORT YOLOv11-seg предоставляет готовый и проверенный пайплайн, способный поддерживать идентичность объектов между кадрами. Благодаря высокой частоте инференса уменьшается вероятность временных разрывов и улучшается устойчивость всей системы трекинга. Альтернативы, такие как DeepLabv3+ или SAM, требуют дополнительных этапов постобработки и не обеспечивают объектно-ориентированного подхода, что усложняет сборку системы.

Третьим фактором выступает применимость модели на встраиваемых и мобильных платформах. YOLOv11-seg легко масштабируется – доступны облегчённые версии, запускаемые на таких устройствах, как NVIDIA Jetson Nano или Xavier NX, без необходимости использовать тяжёлые вычислительные ресурсы. Это делает архитектуру особенно ценной для интеграции в автономные системы мониторинга и роботизированные комплексы. В отличие от ресурсоёмких решений (SAM, Detectron2), YOLOv11-seg легко вписывается в стек на PyTorch, не требуя переноса в другие фреймворки или кардинальной перестройки окружения.

Четвёртым аргументом является простота дообучения и сопровождения. Модель сопровождается обширным инструментарием: встроенная аугментация, автоподбор параметров, продуманная система логирования и мониторинга. Это ускоряет итерации обучения и снижает требования к объёму обучающей выборки. Поддержка со стороны сообщества и документация Ultralytics позволяют оперативно решать возникающие задачи и гибко адаптировать модель под новые требования без глубокого погружения в архитектуру.

Наконец, YOLOv11-seg обладает высоким потенциалом масштабирования. Архитектура уже поддерживает не только сегментацию, но

и классификацию, определение ключевых точек и другие задачи, что делает её перспективной платформой для расширения функционала системы. Таким образом, внедрение YOLOv11-seg обеспечивает основу не только для решения текущей задачи сегментации яблок, но и для возможного добавления новых функций, таких как подсчёт плодов, анализ формы или выявление заболеваний.

3.3.3 Обучение модели YOLOv11-seg

Для обучения модели сегментации на базе YOLOv11-seg использовалась библиотека Ultralytics, предоставляющая удобный высокоуровневый интерфейс. Обучение проводилось на пользовательском датасете, содержащем изображения яблок с вручную размеченными масками в формате COCO. Конфигурация описывалась в YAML-файле, где были указаны пути к изображениям, аннотациям и классу объектов.

```
# Импортируем класс модели YOLO из библиотеки Ultralytics
from ultralytics import YOLO
# Загружаем предобученную модель YOLOv11n с сегментационной головой
# Файл весов может быть либо локальным, либо загружается из репозитория Ultralytics
model = YOLO("yolo11n-seg.pt")
# Запускаем процесс обучения на пользовательском датасете
train_results = model.train(
    data="/home/sarmat/Documents/apple/data/data.yaml", # Путь к YAML-файлу с конфигурацией датасета
    epochs=100, # Количество эпох обучения
    imgsz=640, # Размер входного изображения (640x640)
    device="0" # Выбор устройства: "0" – первый GPU (например, RTX 3080 Ti)
)
```

Рис. 3.19 Фрагмент кода запуска обучения модели YOLOv11-seg

На рисунке 3.19 представлен фрагмент кода, запускающий процесс обучения модели. В качестве предобученной основы использована компактная версия YOLOv11n, предварительно обученная на открытом наборе данных. Обучение проводилось на GPU (RTX 3080 Ti), с разрешением изображений 640×640 пикселей, на протяжении 100 эпох.

Такая конфигурация выбрана как оптимальный компромисс между точностью и скоростью обучения, с учётом ограниченного размера корпуса и требований к скорости инференса в будущем. В частности, облегчённая

архитектура YOLOv11n позволяет сократить время одной эпохи до 2–3 минут на RTX 3080 Ti при сохранении достаточной глубины сегментирующего слоя.

После завершения обучения результаты фиксировались в объекте `train_results`, включающем в себя информацию о значениях функции потерь, метриках точности и количестве эпох. Визуализация этих данных позволяет отследить динамику сходимости модели и оценить её способность к обобщению.

```
import matplotlib.pyplot as plt
# Получаем список номеров эпох (если отсутствует – создаём от 1 до 100)
epochs = train_results.get('epochs', list(range(1, 101)))
# Извлекаем объект с метриками из результатов обучения
metrics = train_results['metrics']
# Получаем списки значений метрик
train_loss = metrics.train_loss      # Потери на обучающей выборке
val_loss = metrics.val_loss          # Потери на валидационной выборке
mAP = metrics.mAP                   # Средняя точность (Mean Average Precision)
# Создаём холст с двумя графиками
plt.figure(figsize=(12, 5))
# --- График функции потерь (Train/Val Loss) ---
plt.subplot(1, 2, 1)
plt.plot(epochs, train_loss, 'b-', label='Train Loss')      # Синяя линия – обучение
plt.plot(epochs, val_loss, 'r-', label='Validation Loss')    # Красная линия – валидация
plt.xlabel('Эпоха')
plt.ylabel('Потеря')
plt.title('Зависимость функции потерь от эпох')
plt.legend()
# --- График средней точности mAP ---
plt.subplot(1, 2, 2)
plt.plot(epochs, mAP, 'g-', label='mAP')
plt.xlabel('Эпоха')
plt.ylabel('mAP')
plt.title('Зависимость mAP от эпох')
plt.legend()
# Финальная визуализация
plt.tight_layout()
plt.show()
```

Рис. 3.20 Визуализация метрик обучения: train/val loss и mAP

На рисунке 3.20 представлен код построения графиков зависимости функции потерь и средней точности по классам (mAP) от количества эпох. В левой части диаграммы отображается снижение значений функции потерь как на обучающей, так и на валидационной выборке, что свидетельствует о корректной настройке процедуры оптимизации. В правой части визуализируется рост значения mAP, отражающий повышение качества детекции и сегментации объектов.

Подобный подход к визуальному контролю обучения модели критически важен в инженерных задачах, поскольку позволяет на раннем этапе зафиксировать признаки переобучения, остановки сходимости или неустойчивости метрик. Далее будет приведён анализ метрик последней эпохи и кривых качества (PR , $F1$), включая выбор оптимального порога уверенности и рекомендации по настройке [113, 114, 117].

3.3.4 Результаты обучения модели

Визуальный анализ метрик обучения и оценки модели на валидационном наборе позволяет сформировать обоснованную картину качества сегментации и трекинга. Графики изменения потерь по различным компонентам (box, segmentation, classification) демонстрируют стабильное снижение, без расхождений между обучающей и проверочной выборками.




Рис. 3.21 График зависимости F1 от порога уверенности (F1-Confidence Curve)

Это указывает на отсутствие переобучения даже на последних эпохах. В финальной фазе обучения наблюдается характерный резкий спад потерь (рис 3.21), что связано с косинусным режимом адаптации learning rate . F1-мера, отражающая баланс между точностью (precision) и полнотой (recall), достигает максимального значения $\approx 0,92$ при пороге уверенности около 0,37. Это значение считается оптимальным и применяется при настройке системы в

задачах, где одинаково важно минимизировать как пропуски объектов, так и ложные срабатывания. Ниже порога 0,2 резко падает точность, выше 0,8 – резко снижается полнота, что типично для моделей с высокой чувствительностью.




Рис. 3.22 График зависимости точности от confidence (Precision-Confidence Curve)

Кривая точности показывает (рис 3.22), что даже при низком пороге (confidence $\sim 0,2$) точность уже превышает 85%, а при 0,936 достигает максимального значения 1.0. Это означает, что слабые предсказания эффективно фильтруются и модель редко ошибается в случае высокой уверенности.




Рис. 3.23 Кривая точность–полнота для box (Precision–Recall Curve, bbox)

Кривая Precision–Recall демонстрирует (рис 3.23) отличное удержание точности при увеличении полноты: вплоть до recall $\approx 0,75$ сохраняется

высокий precision. Средняя точность по IoU 0,5 составляет 0,969, что свидетельствует о надёжной детекции прямоугольников.




Рис. 3.24 Зависимость полноты от confidence (Recall-Confidence Curve)

График recall от confidence (рис 3.24) показывает, что при очень низком пороге ($\approx 0,0$) модель захватывает до 98% всех объектов. Однако с ростом confidence полнота начинает убывать: при пороге 0,9 остаётся лишь $\sim 80\%$ true-positive, подтверждая компромисс между уверенностью и чувствительностью.




Рис. 3.25 F1-метрика по маскам (F1-Confidence Curve, mask)

Кривая F1 для сегментации подтверждает те же тенденции, что и для bbox: максимум F1-достигается при том же confidence $\approx 0,37$, указывая на согласованность между задачами локализации и сегментации (рис. 3.25).




Рис. 3.26 Точность масочной сегментации от порога (Precision-Confidence Curve, mask)

Аналогичная точностная кривая показывает (рис. 3.26), что маски также имеют очень высокую уверенность: при confidence $\approx 0,936$ достигается точность 1,0. Это говорит о надёжной фильтрации шумовых сегментов.




Рис. 3.27 Precision-Recall Curve для масок

Кривая PR для масок даёт значение $mAP@0,5 \approx 0,967$, что лишь немногим уступает bbox-детекции. Точность удерживается вплоть до recall $\sim 0,75$, доказывая высокое качество сегментации (3.27).

Таблица. 3.1. Итоговые метрики (100-я эпоха)

Показатель	Боксовая регрессия	Масочная сегментация
mAP@0,5	0,963	0,967
mAP@0,5–0,95	0,895	0,904
Precision	0,931	0,934
Recall	0,917	0,921
F1 (threshold $\approx$ 0,37)	0,92	0,92

Анализ пороговых значений кривых:

- Оптимальный порог: около 0,37 – обеспечивает наивысшую F1-меру при сбалансированном precision/recall.
- Максимальная точность: при confidence $\sim$ 0,94 точность достигает 1,0, но recall падает до $\sim$ 0,55.
- Общая площадь под PR-кривой: $\approx$ 0,967 (по маскам) – говорит о высокой дискриминативной способности модели.

Ограничения выявленной модели:

1. Центростремлённость – большинство объектов обучающей выборки находятся в центре кадра.
2. Одноклассовость – отсутствие фоновых и конкурирующих классов снижает устойчивость.
3. Формовая однородность – преобладание круглых плодов снижает адаптивность к вытянутым или частично скрытым экземплярам.

Таким образом, модель YOLOv11-seg показала уверенные результаты по всем ключевым метрикам, продемонстрировала стабильность обучения и надёжную работу на тестовой выборке. Полученные графики и пороговые кривые позволяют точно настроить систему под различные сценарии применения. В дальнейших разделах будет рассмотрена реализация трекинга и подключение модели к системе управления сортировкой.

3.4 Реализация системы отслеживания и сохранения объектов из видеопотока

На этапе разработки модель YOLOv11-seg была интегрирована в программный модуль, предназначенный для анализа видеопотока с целью сегментации и трекинга яблок, а также последующего сохранения масок каждого объекта в виде отдельных изображений. Это приближает систему к реальному применению на производственной линии: каждый плод отслеживается во времени и сохраняется для дальнейшего анализа, сортировки или документирования.

```
import os          # Модуль для работы с файловой системой (создание папок, чтение содержимого директорий)
import cv2         # OpenCV: библиотека для обработки изображений и видео
import numpy as np # NumPy: библиотека для работы с массивами и числовых операций
import torch       # PyTorch: фреймворк для глубокого обучения
from ultralytics import YOLO # Класс YOLO из библиотеки ultralytics для сегментации и детекции
# Загрузка предобученной модели YOLO (сегментация) из указанного файла весов
model = YOLO("runs/segment/train9/weights/best.pt")
# Директория для сохранения результатов
output_dir = "output"
# Создаём папку output, если она ещё не существует
os.makedirs(output_dir, exist_ok=True)
# Путь к папке с тестовыми видео
folder_path = "/home/sarmat/Documents/apple/data/test_videos"
try:
    # Проходим по всем файлам в указанной папке
    for filename in os.listdir(folder_path):
        file_path = os.path.join(folder_path, filename)
        # Проверяем, что это файл (не папка)
        if os.path.isfile(file_path):
            print(f"Обрабатывается файл: {file_path}")
            # Формируем папку для сохранения масок данного видео
            # Имя папки совпадает с именем файла без расширения
            out_file = os.path.join(output_dir, filename.split(".")[0])
            os.makedirs(out_file, exist_ok=True)
            # Вызываем функцию обработки видео:
            # - model      : экземпляр YOLO-модели
            # - file_path  : путь к исходному видеофайлу
            # - out_file   : папка для сохранения сегментированных масок
            # - conf=0.3   : порог уверенности для отбрасывания слабых предсказаний
            save_tracked_masks(model, file_path, out_file, conf=0.3)
# Если в процессе возникнет ошибка, она будет поймана и выведена в консоль
except Exception as e:
    print(f"Ошибка при обработке видео: {e}")
```

Рис. 3.28 Запуск обработки видеофайлов и структура сохранения результатов

Программа построена таким образом (рис. 3.28), что для каждого входного видео создаётся структурированное хранилище результатов. Сначала в корневой директории *output* формируется папка с названием видеофайла, а внутри неё – подкаталоги с номерами *track_id*, которые соответствуют уникальным идентификаторам объектов, назначенным

системой трекинга. В этих папках сохраняются PNG-изображения, содержащие сегментированные экземпляры яблок, вырезанные из каждого кадра на основе предсказанных масок. В зависимости от параметров, изображения могут быть сохранены либо на прозрачном фоне, либо на чёрном.

Для реализации этой логики была разработана функция *save_tracked_masks*, которая принимает входной видеофайл и последовательно обрабатывает его покадрово (рис. 3.29) с помощью модели YOLOv11-seg в режиме *track()*. Сама модель предварительно обучена и загружается через интерфейс Ultralytics YOLO. Обработка производится с учётом трек-идентификаторов, извлекаемых из результатов инференса.

```
from ultralytics import YOLO
import os
import cv2
import numpy as np
# Загружаем предобученную модель сегментации YOLOv11 (вариант с обученными весами)
model = YOLO("runs/segment/train9/weights/best.pt")
# Указываем путь к директории с тестовыми видеофайлами
video_dir = "/home/sarmat/Documents/apple/data/test_videos"
# Создаём выходную папку для результатов, если она ещё не существует
output_dir = "output"
os.makedirs(output_dir, exist_ok=True)
# Обходим все файлы в папке с видео
for filename in os.listdir(video_dir):
    file_path = os.path.join(video_dir, filename)
    # Проверяем, что найденный элемент – это файл (а не папка)
    if os.path.isfile(file_path):
        print(f"Обработка: {file_path}")
        # Создаём поддиректорию с именем файла (без расширения) для хранения результатов
        save_dir = os.path.join(output_dir, filename.split(".")[0])
        os.makedirs(save_dir, exist_ok=True)
        # Вызываем функцию, которая выполняет трекинг и сохранение масок объектов
        save_tracked_masks(model, file_path, save_dir, conf=0.3)

def save_tracked_masks(model, video_path, output_dir, conf=0.5, classes=None, transparent_bg=True):
    """
    Сохраняет объекты, выделенные по маске, из видеопотока в виде отдельных изображений.
    Параметры:
    model (YOLO): обученная модель YOLO-сегментации с поддержкой трекинга.
    video_path (str): путь к входному видеофайлу.
    output_dir (str): директория для сохранения результатов.
    conf (float): порог уверенности для фильтрации слабых предсказаний.
    classes (list[int] или None): фильтр по классам (если требуется).
    transparent_bg (bool): если True – сохраняется с прозрачным фоном (альфа-канал), иначе – на чёрном фоне.
    """
```

Рис. 3.29 Начало реализации функции *save_tracked_masks* с документацией параметров

Ключевой особенностью является сохранение объектов в формате *.png*, с возможностью выбора между прозрачным и чёрным фоном. Это удобно как для дальнейшего обучения, так и для визуального контроля. Каждое

изображение подписывается по номеру кадра, из которого оно извлечено (рис. 3.30).

В случае, если на кадре обнаружено несколько объектов, каждый из них сохраняется в свою директорию, соответствующую его уникальному трек-ID. Это обеспечивает логичную структуру хранения и возможность последующего анализа траекторий каждого плода [125, 132, 133].

```
cap = cv2.VideoCapture(video_path)
frame_count = 0 # счётчик кадров
while cap.isOpened():
    success, frame = cap.read()
    if not success:
        break
    h, w = frame.shape[:2]
    # Выполняем инференс и трекинг для текущего кадра
    results = model.track(
        frame,
        conf=conf,
        classes=classes,
        retina_masks=True,
        persist=False,
        verbose=False
    )
    # Проверяем наличие идентификаторов и масок
    if results[0].boxes.id is not None and results[0].masks is not None:
        boxes = results[0].boxes.xyxy.cpu().numpy().astype(int)
        ids = results[0].boxes.id.cpu().numpy().astype(int)
        masks = results[0].masks.data.cpu().numpy()
        for box, track_id, mask in zip(boxes, ids, masks):
            # Масштабируем маску до размеров оригинального кадра
            mask = cv2.resize(mask, (w, h), interpolation=cv2.INTER_NEAREST)
            if transparent_bg:
                obj = cv2.cvtColor(frame, cv2.COLOR_BGR2BGRA)
                obj[:, :, 3] = (mask > 0) * 255
            else:
                binary = ((mask > 0).astype(np.uint8) * 255)
                obj = cv2.bitwise_and(frame, frame, mask=binary)
            # Добавляем паддинг к bbox для аккуратного кадрирования
            pad = 5
            x1, y1, x2, y2 = box
            x1 = max(0, x1 - pad)
            y1 = max(0, y1 - pad)
            x2 = min(w, x2 + pad)
            y2 = min(h, y2 + pad)
            crop = obj[y1:y2, x1:x2]
            if crop.size == 0:
                continue
            obj_dir = os.path.join(output_dir, str(track_id))
            os.makedirs(obj_dir, exist_ok=True)
            out_path = os.path.join(obj_dir, f"obj_{frame_count}.png")
            cv2.imwrite(out_path, crop)
        frame_count += 1
cap.release()
```

Рис. 3.30 Логика обработки кадров: от трекинга до сохранения масок

На рисунке 3.31 показан пример сохранённых изображений одного отслеженного яблока. Видно, что маска корректно отделяет объект от фона, даже в случае его вращения и частичного перекрытия бликами. Все изображения аккуратно выровнены, обрезаны с паддингом и готовы для последующего анализа формы, текстуры или оценки дефектов.



Рис. 3.31 Логика обработки кадров: от трекинга до сохранения масок

Структура сформированного хранилища представлена на рисунке 3.32. Здесь можно проследить вложенность: корневая папка содержит имя видеофайла (*IMG_5747*), а далее идут числовые *ID* объектов (например, 1124), внутри которых хранятся кадры с именами *obj_XXX.png*, где *XXX* – номер фрейма.



Рис. 3.32 Логика обработки кадров: от трекинга до сохранения масок

В дальнейшем подобная система может быть дополнена логикой агрегации данных: подсчётом количества уникальных объектов, анализом продолжительности присутствия в кадре, оценкой средней скорости движения и других характеристик. Это делает модуль не только компонентом визуального контроля, но и потенциальной аналитической платформой в составе системы автоматического сортировщика.

3.5 Реализация алгоритма оценки объема повреждения плода при помощи системы компьютерного зрения

3.5.1 Основной цикл определения повреждения плода

Этапом аналитического модуля, дополняющим сегментацию и трекинг, становится количественная оценка повреждений каждого плода. Основная цель – определить, является ли объект испорченным на основании доли повреждённого объёма относительно целого яблока.

```
import cv2 # Библиотека OpenCV для работы с изображениями и видео
import os  # Модуль для работы с файловой системой
import math # Модуль для математических операций
from tqdm import tqdm # tqdm – удобный прогресс-бар для циклов
def process_objects(output_dir):
    """
    Обработывает все объекты (изображения) в подпапках директории output_dir,
    рассчитывает статистику: общее число объектов и число повреждённых.
    Параметры:
        output_dir (str): путь к директории, содержащей папки с видео,
                        в которых лежат подпапки-объекты.
    Возвращает:
        list of dict: список словарей со статистикой по каждому видео:
        {
            "video_name": имя видео (папки),
            "total_objects": общее количество объектов,
            "damaged_objects": количество объектов с повреждением >5%
        }
    """
    # Поддерживаемые расширения файлов изображений
    image_extensions = {'.jpg', '.jpeg', '.png', '.bmp', '.gif', '.tiff', '.webp'}
    # Словарь для накопления статистики: {video_name: {'total_objects': X, 'damaged_objects': Y}}
    video_stats = {}
    # Список всех объектов в формате (video_name, path_to_object_folder)
    all_objects = []
    # Шаг 1: Собираем список всех объектов и инициализируем статистику по каждому видео
    for video_name in os.listdir(output_dir):
        video_path = os.path.join(output_dir, video_name)
        if not os.path.isdir(video_path):
            # Пропускаем файлы, оставляем только папки (каждая папка – отдельное видео)
            continue
        # Инициализируем счётчики для текущего видео
        video_stats[video_name] = {
            'total_objects': 0,
            'damaged_objects': 0
        }
        # Проходим по подпапкам внутри папки видео – это наши объекты
        for object_folder in os.listdir(video_path):
            object_path = os.path.join(video_path, object_folder)
            if os.path.isdir(object_path):
                # Сохраняем пару (название видео, путь к объекту) для последующей обработки
                all_objects.append((video_name, object_path))
```

Рис. 3.33 Предобработка структуры директорий и обход объектов по видеофайлам

Для этого применяется алгоритм, анализирующий вырезанные сегментированные изображения, полученные ранее, и производящий оценку площади и примерного объёма маски повреждения.

Основная функция *process_objects()* реализует полный цикл анализа. На вход она получает путь к директории *output*, в которой хранятся результаты трекинга: отдельные папки по видеофайлам, а внутри – папки по ID каждого объекта. Каждая такая папка содержит серию PNG-файлов, соответствующих кадрам, на которых отслеживался плод [160, 161, 166].

В рамках первого этапа происходит проход по всем видео-папкам и инициализация счётчиков – общее число объектов и количество повреждённых. Далее начинается покадровый анализ: для каждого изображения внутри объекта вызывается функция *analyze_apple_damage()*, возвращающая площади сегментированных областей: яблока и повреждённого участка. При наличии валидных данных производится расчёт объёма через функцию *calculate_volumes()*, которая может быть как простой (например, сферическая модель), так и приближённо параметризованной. Если хотя бы на одном из кадров доля повреждённой части превышает 5% от общего объёма, объект считается повреждённым.

На рисунке 3.33 представлен фрагмент кода, отвечающего за предобработку и итерацию по всем видео и объектам внутри них. Именно здесь инициализируются структуры для статистики, отсеиваются недопустимые форматы файлов и происходит первичное накопление данных.

Далее, в основной части кода, осуществляется цикл анализа каждого изображения: вызывается сегментационный анализ, производится проверка корректности площадей и расчёт модельного объёма (рис. 3.34). В случае превышения установленного порога повреждения объект помечается как бракованный. После завершения обработки формируется таблица, где по каждому видео указывается общее число найденных плодов, количество признанных испорченными и процентное соотношение.

```

# Шаг 2: Обрабатываем каждый объект с прогресс-баром
for video_name, object_path in tqdm(all_objects, desc="Обработка"):
    stats = video_stats[video_name]
    stats['total_objects'] += 1 # Увеличиваем счётчик общего числа объектов
    damaged = False # Флаг, найдено ли повреждение в текущем объекте
    # Проходим по файлам внутри папки объекта
    for file_name in os.listdir(object_path):
        file_path = os.path.join(object_path, file_name)
        ext = os.path.splitext(file_name)[1].lower() # Расширение файла в нижнем регистре
        # Проверяем, что это файл изображения нужного формата
        if os.path.isfile(file_path) and ext in image_extensions:
            # Анализируем изображение: получаем словарь с площадями яблока и повреждения
            local_result = analyze_apple_damage(file_path, visualize=False)
            a_area = local_result['apple_area'] # Площадь яблока
            d_area = local_result['damage_area'] # Площадь повреждения
            # Если одна из площадей нулевая или отрицательная – пропускаем
            if a_area <= 0 or d_area <= 0:
                continue
            # Рассчитываем объёмы (модельная функция)
            volumes = calculate_volumes(a_area, d_area)
            a_volume = volumes['apple_volume'] # Объём яблока
            d_volume = volumes['damage_volume'] # Объём повреждения
            # Если доля повреждения больше 5% – считаем объект повреждённым
            if (d_volume / a_volume) > 0.05:
                damaged = True
                break # Достаточно одного повреждённого изображения для пометки всего объекта
    # Если нашли повреждение – увеличиваем соответствующий счётчик
    if damaged:
        stats['damaged_objects'] += 1
# Шаг 3: Формируем итоговый список статистики для вывода
result = []
for name, data in video_stats.items():
    result.append({
        "video_name": name,
        "total_objects": data["total_objects"],
        "damaged_objects": data["damaged_objects"]
    })
return result
if __name__ == "__main__":
    # Путь к директории с распакованными видео (каждая папка – отдельное видео)
    output_directory = "output"
    # Получаем статистику по всем видео
    stats = process_objects(output_directory)

    # Печатаем заголовок таблицы
    print("{:<15} | {:>10} | {:>10} | {:>10}".format(
        "Видео", "Всего", "Повреждено", "%"))
    print("-" * 55)

    # Выводим статистику по каждому видео в формате CSV
    for entry in stats:
        total = entry["total_objects"]
        damaged = entry["damaged_objects"]
        percent = damaged / total * 100 if total > 0 else 0
        # Формируем строку: video_name,total,damaged,percentage%
        print("{},{},{},{:.2f}%".format(
            entry["video_name"],
            total,
            damaged,
            percent
        ))

```

Рис. 3.34 Анализ повреждения на основе площади маски и подсчёт доли брака по видео

Такая процедура позволяет не просто идентифицировать дефекты визуально, но и формировать агрегированную статистику по партиям яблок, автоматизируя контроль качества и отбраковку. В следующем разделе будет подробно описан метод получения площади и объёма по маске (функции *analyze_apple_damage()* и *calculate_volumes()*), а также приведены примеры корреляции с реальными физическими повреждениями, измеренными на взвешенных образцах [167].

3.5.2 Функция расчета объема и радиуса плода

Важным элементом расчётного блока системы анализа плодов выступает функция *calculate_volumes()*, реализующая приближённую оценку объёма как самого яблока, так и его повреждённой части на основе сегментированных масок. Цель этой функции – преобразовать двумерную информацию площадь проекции в трёхмерные параметры (радиус и объём), используя простую, но физически интерпретируемую модель.

Исходными параметрами функции являются площади двух объектов: всей проекции плода (*apple_area*) и области дефекта (*damage_area*). Предполагается, что обе области приближённо имеют форму круга, что типично для проекций с верхней камеры при вертикальной ориентации яблока на конвейере. Радиусы вычисляются согласно стандартной формуле: $r = \sqrt{\frac{A}{\pi}}$, где A - площадь в пикселях, полученная из маски сегментации; r - радиус объекта.

Для яблока в целом принимается, что оно имеет форму сферы. Это не только удобно с точки зрения геометрии, но и приближённо соответствует реальной форме плодов сорта Golden, используемых в испытаниях. Расчеты производятся согласно выражениям (2.4) – (2.9), приведенные во 2 главе.

Такое двойное приближение позволяет лучше аппроксимировать реальные неровности дефектов, особенно в случаях, когда сегментация фиксирует не только плоские, но и частично объёмные вмятины.

Возвращаемый результат оформляется в виде словаря с ключами *apple_radius*, *damage_radius*, *apple_volume*, *damage_volume*, что упрощает логирование и анализ на последующих этапах.

На рисунке 3.35 представлена реализация данной функции на языке Python. Отдельно стоит отметить чистоту структуры и сопровождающие комментарии, позволяющие без труда перенести логику в другие языки программирования или аппаратные среды.

```
import math
def calculate_volumes(apple_area, damage_area):
    """
    Функция для вычисления:
    1) Радиуса яблока (на основе площади apple_area)
    2) Радиуса повреждения (на основе площади damage_area)
    3) Объёма яблока (принимая его за сферу)
    4) Объёма повреждения, рассчитанного как среднее арифметическое
       между объемом полусферы (с радиусом, равным радиусу повреждения)
       и объемом конуса (с основанием диаметра повреждения и высотой, равной радиусу повреждения)
    Параметры:
        apple_area (float): площадь проекции яблока (предполагается, что это круг,  $A = \pi r^2$ )
        damage_area (float): площадь проекции повреждения (аналогично, круг)
    Возвращает:
        dict: словарь с ключами:
            'apple_radius' – вычисленный радиус яблока,
            'damage_radius' – вычисленный радиус повреждения,
            'apple_volume' – объём яблока (сфера),
            'damage_volume' – объём повреждения (среднее значение между полусферой и конусом)
    """
    # Вычисление радиусов через формулу  $A = \pi * r^2 \Rightarrow r = \sqrt{A/\pi}$ 
    apple_radius = math.sqrt(apple_area / math.pi)
    damage_radius = math.sqrt(damage_area / math.pi)
    # Объём яблока (предположим, что яблоко – это сфера):
    #  $V = (4/3) * \pi * r^3$ 
    apple_volume = (4/3) * math.pi * (apple_radius ** 3)
    # Объём повреждения рассчитывается как среднее арифметическое двух моделей:
    # 1) Полусфера (где радиус равен damage_radius)
    hemisphere_volume = 0.5 * (4/3) * math.pi * (damage_radius ** 3)
    # 2) Конус:
    #  $V = (1/3) * \pi * r^2 * h$ ,
    # где  $h \approx$  damage_radius, основание – круг радиуса damage_radius
    cone_volume = (1/3) * math.pi * (damage_radius ** 2) * damage_radius
    # Среднее арифметическое из двух объёмов
    damage_volume = (hemisphere_volume + cone_volume) / 2
    return {
        'apple_radius': apple_radius,
        'damage_radius': damage_radius,
        'apple_volume': apple_volume,
        'damage_volume': damage_volume
    }
```

Рис. 3.35 Функция расчёта объёма яблока и повреждения на основе сегментированной площади

Таким образом, функция *calculate_volumes* становится связующим мостом между визуальной сегментацией и физически значимой метрикой – объёмом повреждения. Это критически важно для автоматизированной системы отбора, где пороговые значения определяются не эстетическими, а технологическими требованиями к качеству сырья для переработки.

3.5.3 Программная реализация нечеткой системы принятия решений для оценки качества яблок

Завершающим элементом расчетов, реализуется блок нечеткой системы классификации яблок, основанный на методологии, описанной в п.п. 2.4. Главная цель данного сегмента – задать функции принадлежности для всех четырёх ключевых входных переменных: степени повреждения, цветового соответствия, формы плода и его размера. Именно эти параметры легли в основу системы принятия решений по итоговому классу пригодности.

На начальном этапе определены универсальные функции принадлежности: *trapezoid* и *triangle* (рис. 3.36). Они формализуют способ описания лингвистических переменных в терминах нечёткой логики. Первая функция позволяет описывать трапециевидные области (например, понятие "соответствующий цвет" или "эллипсоидная форма"), а вторая применяется для треугольных термов – таких как "малый" или "средний".

Далее каждая входная переменная разделяется на три терма с соответствующими границами, подобранными из анализа эмпирических данных. Важно, что каждая функция принадлежности реализована как конкретный числовой механизм, возвращающий степень принадлежности в диапазоне от 0 до 1. Это обеспечивает числовую основу для дальнейшей логики вывода, которая затем участвует в построении агрегированного *Q*-оценивания.

Фрагмент кода, представленный на рисунке 3.36 формирует базу нечеткой логики, на которой распределяется приоритетная иерархия правил и окончательная классификация пригодности плодов по категориям: от утиля до

товарной продукции. Именно здесь формируются термы, обеспечивающие плавный переход между крайними значениями признаков и логической интерпретацией результата.

```
import numpy as np
# Функции принадлежности
def trapezoid(x, a, b, c, d):
    return max(min((x - a) / (b - a), 1, (d - x) / (d - c)), 0)
def triangle(x, a, b, c):
    return max(min((x - a) / (b - a), (c - x) / (c - b)), 0)
# Нечеткие множества по входным признакам
def fuzzify_damage(damage):
    return {
        'малый': trapezoid(damage, 0.0, 0.0, 0.1, 0.2),
        'средний': triangle(damage, 0.15, 0.3, 0.45),
        'высокий': trapezoid(damage, 0.4, 0.6, 1.0, 1.0)
    }
def fuzzify_color(color):
    return {
        'соответствует': trapezoid(color, 0.8, 0.9, 1.0, 1.0),
        'пограничное': triangle(color, 0.5, 0.65, 0.8),
        'не соответствует': trapezoid(color, 0.0, 0.0, 0.4, 0.6)
    }
def fuzzify_shape(shape):
    return {
        'сферическая': trapezoid(shape, 0.8, 0.9, 1.0, 1.0),
        'средняя': triangle(shape, 0.5, 0.65, 0.8),
        'эллипсоидная': trapezoid(shape, 0.0, 0.0, 0.4, 0.6)
    }
def fuzzify_size(size):
    return {
        'малый': trapezoid(size, 0.0, 0.0, 0.3, 0.4),
        'средний': triangle(size, 0.35, 0.5, 0.65),
        'большой': trapezoid(size, 0.6, 0.7, 1.0, 1.0)
    }
```

Рис. 3.36 Формализация лингвистических переменных и нечёткая интерпретация признаков входных параметров

Вторая часть кода реализует логическую надстройку над функциями принадлежности, формируя финальный механизм принятия решения на основе иерархии (рис. 3.37). В самом начале определена функция *apply_rules*, в которой реализована приоритетная система нечётких правил.

```

# Иерархия правил (по приоритету)
def apply_rules(d, c, f, s):
    if d['высокий'] > 0:
        return 0.12 # Утиль
    if (d['средний'] > 0 or d['малый'] > 0) and c['не соответствует'] > 0:
        return 0.34 # Корм животным
    if (d['средний'] > 0 or d['малый'] > 0) and \
        (c['соответствует'] > 0 or c['пограничное'] > 0) and \
        f['сферическая'] > 0:
        return 0.92 # Продажа / хранение
    if (d['средний'] > 0 or d['малый'] > 0) and \
        (c['соответствует'] > 0 or c['пограничное'] > 0) and \
        (f['средняя'] > 0 or f['эллипсоидная'] > 0) and \
        (s['средний'] > 0 or s['большой'] > 0):
        return 0.72 # Сок
    if (d['средний'] > 0 or d['малый'] > 0) and \
        (c['соответствует'] > 0 or c['пограничное'] > 0) and \
        (f['средняя'] > 0 or f['эллипсоидная'] > 0) and \
        s['малый'] > 0:
        return 0.52 # Пюре
    return 0.4 # Условно пригодные по умолчанию
# Интерпретация результата
def interpret_q(q):
    if q < 0.24:
        return "Утиль"
    elif q < 0.44:
        return "Корм животным"
    elif q < 0.60:
        return "Пюре"
    elif q < 0.84:
        return "Сок"
    else:
        return "Продажа / хранение"
# Основная функция классификации яблока
def classify_apple(damage, color, shape, size):
    fuzz_d = fuzzify_damage(damage)
    fuzz_c = fuzzify_color(color)
    fuzz_f = fuzzify_shape(shape)
    fuzz_s = fuzzify_size(size)
    q = apply_rules(fuzz_d, fuzz_c, fuzz_f, fuzz_s)
    label = interpret_q(q)
    return q, label
# Вывод
if __name__ == "__main__":
    q_score, decision = classify_apple(damage=0.2, color=0.85, shape=0.9, size=0.4)
    print(f"Q = {q_score:.2f} → Результат: {decision}")

```

Рис. 3.37 Преобразование числовых характеристик в степени принадлежности лингвистических категорий

Каждое правило задано в виде условия с логическими операторами и возвращает фиксированное значение Q в диапазоне от 0 до 1. Например, если

степень повреждения классифицирована как "высокая", система сразу присваивает значение $Q = 0,12$, соответствующее категории "утиль". Далее срабатывают менее приоритетные правила – например, комбинация умеренного повреждения с несоответствием цвета даёт $Q = 0,34$ и классифицирует объект как пригодный только для корма.

Особенность реализации в том, что каждое правило работает не на базе присвоения весов, а на основе значений принадлежности, полученных ранее. Это позволяет учитывать частичную степень соответствия каждого признака и формировать более гибкие логические конструкции. После того как все правила проверены, итоговое значение Q передаётся на этап интерпретации.

Функция *interpret_q* сопоставляет числовое значение Q с лингвистической категорией. Разбивка значений строго следует классификации из второй главы: от утиля ($Q < 0,24$) до категории "продажа/хранение" ($Q > 0,84$). Это превращает числовой результат в удобную метку, пригодную для использования в реальной сортировочной системе.

Функция *classify_apple* объединяет все этапы: входные признаки, применение правил и интерпретацию результата. В конце кода приведён тестовый пример вызова, где объект с параметрами (например, *damage*=0,2, *color*=0,85) классифицируется с выводом итогового Q -оценивания и текстового ярлыка пригодности [140, 154, 156].

Данный фрагмент кода завершает полный цикл нечеткой классификации от обработки исходных физических параметров до получения чёткого и интерпретируемого результата, сформированного во 2 главе.

3.6 Реализация управления ПЛК

В рамках обеспечения полноты автоматизации сортировочной линии, особое внимание было уделено реализации аппаратного управления системой отбраковки дефектных плодов с использованием программируемого логического контроллера ПЛК. Этот блок является связующим звеном между

высокоуровневым интеллектуальным модулем анализа изображений и исполнительными механизмами сортировочной установки.

Процесс сортировки спроектирован так, чтобы гарантировать автоматическое удаление продукции, не соответствующей заданным параметрам качества: цвет, форма, наличие повреждений кожуры. Система машинного зрения, установленная в зоне Z_0 , классифицирует плоды и отмечает те, что подлежат отбраковке. Идентификаторы этих плодов и их координаты передаются в блок управления выбросом, например, на привод исполнительных механизмов. При скорости транспортной ленты до 40 метров в минуту система обязана обеспечивать производительность не ниже 10 яблок в секунду с задержкой реакции не более 50 миллисекунд. Такой уровень требует не только высокой скорости вычислений, но и точного временного согласования между логикой ПЛК и механикой. Для предотвращения повторных срабатываний реализован специализированный алгоритм фильтрации и буферизации команд [91, 103, 104].

Анализ вариантов исполнительных механизмов показал, что при столь коротком цикле пневматика находится на границе своих динамических возможностей. При массе яблока 180 г и требуемом ускорении около 50 G расчётная пиковая сила составляет ~ 90 Н. Поэтому было принято решение использовать сервопривод *MR-JE-20A* мощностью 50 Вт, связанный с коленчатым выбрасывающим механизмом. Он способен обеспечить усилие до 150 Н и реализовать полный рабочий ход 30 мм за 60 мс. Это решение не только покрывает технические требования, но и даёт ряд эксплуатационных преимуществ: регулируемая сила удара, возможность прецизионной остановки в заданной позиции, а также мягкий режим для работы с хрупкими сортами. В аварийных ситуациях предусмотрен резерв на пневмоцилиндр: контроллер *FX5U* поддерживает как импульсные, так и релейные выходы.

Архитектура системы построена на следующих элементах: контроллер *FX5U-32MR/ES* с поддержкой *Ethernet* и импульсного вывода, модуль *FX5-40SSC-S* для управления четырьмя осями через *SSCNET III/H*,

сервопривод *MR-JE-20A* в комплекте с двигателем *HG-KR13*, инкрементальный энкодер на 1024 имп./об. для отслеживания положения яблоч, и система машинного зрения на базе камеры *Basler ace U*, работающая под управлением *OpenCV*. Обмен данными между ПК и ПЛК организован по протоколу *MC (SLMP)* через *Ethernet* (рис. 3.38).

```
# pip install pymcprotocol==0.5.2
from pymcprotocol import Type3E
from struct import pack
plc = Type3E()
plc.connect('192.168.0.10', 5000)
SEQ = 0
while True:
    frame = camera.get_result() # {seq, rejected}
    data = 1 if frame['rejected'] else 0
    plc.batchwrite_bitrandom('M', [1000], [data]) # M1000 - вход FIFO
    plc.batchwrite_wordrandom('D', [2000], [SEQ]) # D2000 - ID для трассировки
    SEQ += 1
```

Рис. 3.38 Код обмена между ПК и контроллером *FX5U* по протоколу *SLMP (Python)*

Логика работы организована следующим образом. На ПК формируется структура $\{SeqID, RejectFlag\}$, где флаг *Reject* указывает, подлежит ли объект выбросу. Эти данные отправляются по TCP (порт 5000) на контроллер. На стороне ПЛК сигнал записывается в кольцевой буфер *RejectFIFO* длиной N тактов, где N определяется числом импульсов от $Z0$ до зоны выброса $Z1$ (расстояние преобразовано в импульсы энкодера). Каждый новый импульс от энкодера сдвигает указатель буфера. Когда *FIFO* выдаёт единичное значение на выходе, формируется команда на сервопривод: абсолютное позиционирование затвора с профилированным ускорением и перемещением на фиксированное значение (например, 35 мм). Команда *MRP* отрабатывается через *Simple Motion*, и после подтверждения выполнения (флаг *Done*) на ПК отправляется *ACK*. Дополнительно каждые 100 тактов *PLC* формирует *JSON*-сводку с параметрами работы, что позволяет вести диагностику в реальном времени [115, 119, 120].

Программная реализация со стороны ПК выполнена на языке *Python 3.11* с использованием библиотеки *pymcprotocol*. Код содержит подключение к

ПЛК, генерацию команд на основе результата машинного зрения и передачу соответствующих битов и *ID* в области памяти контроллера. Это позволяет верифицировать прохождение каждой единицы продукции по идентификатору и минимизировать шанс неконтролируемых выбросов (рис. 3.39).

```
(* === Параметры === *)
CONST
    PULSES_TO_EJECT : INT := 850;    (* Z0→Z1 в импульсах *)
END_CONST
VAR
    RejectFIFO : ARRAY[0..849] OF BOOL := [FALSE];
    idx        : INT := 0;
END_VAR
(* --- Прерывание от энкодера INT0 (каждый импульс) --- *)
idx := (idx + 1) MOD PULSES_TO_EJECT;
RejectFIFO[idx] := M1000;            (* бит от ПК *)
IF RejectFIFO[(idx + 1) MOD PULSES_TO_EJECT] THEN
    (* Absolute Move к позиции выброса (35 мм) *)
    MCRA_Pulse(OutputAxis := 1,
                Position    := 35000,
                Speed       := 200000,
                Accel       := 10000,
                Decel       := 10000,
                Execute     := TRUE);
END_IF;
```

Рис. 3.39 ST-код обработки *RejectFIFO* и управления серводвигателем на *FX5U*

На стороне контроллера (среда *GX Works3*, язык *ST*) реализован цикл прерывания от энкодера: сдвиг указателя, запись *Reject*-флага, проверка на необходимость выброса и выполнение команды *MCRA_Pulse* для управления серво. Использование импульсных выходов *Y0/Y1* и встроенной линейной интерполяции обеспечивает высокую точность и воспроизводимость срабатываний.

Система прошла стресс-тестирование на выборке в 10 000 псевдослучайных объектов с вероятностью *Reject*=0,17. Зафиксировано менее 0,03% ложных срабатываний. Механизмы SIL-контроля состояния сервопривода (контакты *STO* и контроль *SB200*), звуковая сигнализация при

потере связи (бит M1100) и режим «*Pass-Through*» при сетевых задержках свыше 100 мс обеспечивают высокий уровень надёжности.

В результате переход на платформу *FX5U* позволил увеличить резерв времени на обработку событий почти вдвое благодаря встроенному 200 кГц импульсному выходу и использованию сервопривода *MR-JE*. Протокол *SLMP* упростил интеграцию с ПК, устранив необходимость в *OPC*-сервере. А модуль *Simple Motion* открыл возможности масштабирования до четырёх независимых осей для последующих расширений линии сортировки. В ходе длительной эксплуатации (более 8 часов при скорости 35 м/мин) система показала устойчивость и отсутствие сбоев, что подтверждает её готовность к промышленному внедрению.

3.7 Выводы по третьей главе

В третьей главе была разработана и реализована программная часть интеллектуальной автоматизированной системы сортировки яблок. В результате проведенных исследований и экспериментов достигнуты следующие ключевые результаты.

Выбрана и обучена сверточная нейронная сеть *YOLOv11-seg* для решения задачи сегментации яблок и выделения областей повреждений. Достигнута точность масочной сегментации $mAP@0,5 = 0,967$, что подтверждает высокую эффективность выбранной архитектуры для поставленной задачи. Установлено, что оптимальный порог уверенности для детекции составляет 0,37, обеспечивающий наилучший баланс между точностью и полнотой.

Реализован алгоритм оценки объема повреждения плода при помощи системы компьютерного зрения на основе расчетов площадей дефектов, полученных с помощью нейронной сети. Показана возможность количественной оценки степени повреждения яблок с использованием предложенной методики.

Разработан и протестирован механизм передачи данных и управляющих сигналов на программируемый логический контроллер для организации управления сортировочным оборудованием. Программная реализация позволяет в автоматическом режиме выполнять все этапы сортировки яблок, начиная от захвата и предобработки изображений и заканчивая управлением исполнительными механизмами.

4. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ СОРТИРОВКИ ПЛОДОВ

4.1 Физическая модель и методика экспериментальных исследований

Разработанная в рамках настоящей диссертационной работы интеллектуальная автоматизированная система сортировки плодов, базирующаяся на алгоритмах машинного обучения и анализе изображений, полученных с помощью технического зрения, представляет собой комплексное решение для повышения эффективности послеуборочной обработки сельскохозяйственной продукции. Несмотря на перспективность теоретических разработок (глава 2) и моделирование (глава 3), важным этапом в подтверждении их практической ценности является проведение всесторонних экспериментальных исследований [18, 21].

Экспериментальная проверка необходима для валидации заявленных, характеристик разработанной системы, оценки ее применимости в реальных условиях и выявления потенциальных ограничений. В частности, необходимо установить, насколько эффективно алгоритмы машинного обучения справляются с распознаванием дефектов в условиях естественной вариабельности формы, цвета и текстуры плодов, а также разнообразия видов повреждений.

Таким образом, цели экспериментальных исследований заключаются не только в подтверждении работоспособности системы, но и в получении количественных характеристик ее эффективности, выявлении потенциальных проблем и оптимизации параметров для достижения максимальной производительности в реальных условиях эксплуатации. Результаты, полученные в ходе экспериментов, станут основой для оценки практической значимости разработанной системы и определения перспектив ее дальнейшего развития.

4.1.1 Технические средства эксперимента

Для проведения экспериментальных исследований была разработана специализированная установка, имитирующая основные этапы автоматизированного процесса сортировки плодов. Конструкция установки (рис. 4.1) обеспечивает возможность варьирования ключевых параметров, влияющих на работу системы технического зрения и алгоритмов машинного обучения, а также позволяет проводить измерения основных характеристик процесса сортировки.




Рис. 4.1. Физическая модель интеллектуальной управляющей системы оценки качества плодов: 1 – блок обработки и принятия решений; 2 – блок управления (программируемый логический контроллер); 3 – сенсорный блок (видеокамера); 4 – заслонки с позиционным приводом; 5 – средство измерения угла наклона транспортера; 6 – объект детектирования (плоды); 7 – средство измерения расстояния до камеры; 8 – ленточный транспортер; 9 – электродвигатель; 10 – частотный регулятор

Специализированное программное обеспечение, осуществляющее обработку видеоданных, поступающих с сенсорного блока 3, устанавливается в блок обработки и принятия решений 1, анализирует визуальные характеристики плодов, в том числе, форму, наличие дефектов и др. На основании полученной информации данный блок формирует решения

относительно качества каждого плода и передает управляющие команды на последующие элементы системы [25, 39].

Блок управления 2, представленный программируемым логическим контроллером (ПЛК) выполняет функцию аппаратного интерфейса между блоком обработки 1 и исполнительным механизмом 4, обеспечивая синхронизацию их работы. ПЛК отвечает за реализацию алгоритмов сортировки и контроля, а также взаимодействие с датчиками позиционного привода заслонок 4 [116, 120].

Сенсорный блок 3 включающий видеокамеру, служит для получения визуальной информации о плодах, движущихся по транспортеру. Камера фиксирует изображения плодов с необходимым разрешением и передает их в блок обработки 1 для последующего анализа. Для обеспечения корректного восприятия изображения и точности анализа используется средство измерения расстояния 7 до камеры.

Заслонки с позиционным приводом 4, являются исполнительными механизмами, предназначенными для сортировки плодов в зависимости от принятого решения системы. Управляемые программируемым логическим контроллером 2, заслонки открываются или закрываются, направляя плоды в соответствующие категории или отводя плоды с дефектами, что обеспечивает автоматизацию процесса сортировки. Для корректировки параметров движения плодов на транспортерной ленте используется средства измерения угла наклона (транспортир) [57, 64].

Основным элементом транспортировки плодов является ленточный транспортер 8, который обеспечивает равномерное и контролируемое движение плодов через зону контроля и сортировки. Привод ленточного транспортера осуществляется с помощью электродвигателя 9, скорость вращения которого регулируется посредством частотного регулятора. Частотный регулятор позволяет изменять скорость движения транспортера в зависимости от текущих условий работы системы и характеристик поступающих плодов, обеспечивая оптимальные режимы работы системы в

целом. При этом, для обеспечения вращения плода в зоне действия видеокамеры движения транспортера осуществляется против движения качения яблок.

Марки основных технических средств физической модели, а также их характеристики представлены в приложении 7.

4.1.2 Методика проведения экспериментальных исследований

Эффективность интеллектуальной автоматизированной системы сортировки плодов определяется комплексом факторов, связанных как с параметрами системы технического зрения, так и с характеристиками обрабатываемого продукта. Для выявления наиболее значимых факторов и оценки их влияния на точность и скорость сортировки был спланирован и проведен многофакторный эксперимент.

Методологию исследования систем машинного зрения с искусственным интеллектом целесообразно определить тремя направлениями, именно: формирование и оптимизация нейронной сети; разработка физической модели и плана эксперимента для подтверждения характеристик; получение, обработка и обобщение результатов.

Алгоритм предлагаемого подхода представим в виде диаграмм нотации моделирования бизнес-процессов (*BPMN*), позволяющих однозначно документировать последовательность этапов действий, решений и взаимодействий в рамках сложного исследовательского процесса. Визуализация в *BPMN* облегчает восприятие логики, структуры исследования и устраняет неоднозначности [137, 163, 165].

Создание диаграммы *BPMN* требует детального анализа и формализации каждого этапа исследования, позволяет выявить потенциально проблемные места, дублирование или неэффективные процедуры. Этим достигается оптимизация алгоритма исследования, сокращение затрат времени и ресурсов, повышение качества получаемых результатов.

С учетом рекомендаций предложен подход к исследованию систем интеллектуального управления и контроля на основе системы технического зрения (СТЗ) и сверточной нейронной сети (СНС) для оценки качества плодоовощной продукции (рис. 4.2).

Перед физическим экспериментом разрабатывается и оптимизируется нейронная сеть, реализующая задачу оценки качества плодов по их изображениям, в том числе выявление повреждений, классификация по цвету, зрелости и др. Подробное обоснование выбора архитектуры СНС, настройка ее гиперпараметров, обучения и тестирования представлены в главе 3.

Проектирование и создание физической модели и плана эксперимента является заключительным этапом разработки системы интеллектуального управления и контроля; алгоритм этого этапа показан в виде схемы BPMN на соответствующей дорожке (рис. 4.2).

Определяющими выходными параметрами создаваемой многофакторной системы являются производительность при сортировке и ошибка $Loss$ оценки качества плодов, на которые существенно влияют расстояние h от камеры до объекта детектирования (плода), угол наклона α и скорость транспортера v , значения которых позволяют оптимизировать сбор данных, обработку изображений и принятие решений в реальном времени.

Выбор факторов базировался на анализе конструкции установки, особенностей технологического процесса и потребностей в оптимизации системы. Высота h установки камеры (X_1) влияет на ширину зоны обзора, резкость фиксируемых объектов и стабильность анализа изображения.

С учетом рекомендаций [105, 124] и опыта проектирования [32] выбраны следующие значения h :

– $h_{min} = 27$ см: минимальная высота, при которой камера фиксировала плоды с высокой детализацией, но суженной зоной обзора. Это обеспечивало детальное распознавание дефектов, но требовало высокой точности прокатки яблок.

– $h_0 = 41$ см: промежуточное положение, обеспечивающее баланс между детализацией и шириной зоны обзора.

– $h_{max} = 55$ см: максимальная высота, увеличивающая ширину охватываемой области до 34 см. Это давало возможность фиксировать крупные объекты, но снижало качество детектирования мелких дефектов.

Скорость v транспортера (X_2) определяла динамику прокатки яблок и зависела от пропускной способности системы. Были выделены три уровня:

– $v_{min} = 0,10$ м/с: минимальная скорость, обеспечивающая детальное сканирование поверхности яблок за счёт длительного времени обработки. Этот режим позволял получать наилучшее качество анализа, но снижал производительность.

– $v_0 = 0,20$ м/с: средняя скорость, представлявшая собой компромисс между производительностью и качеством обработки.

– $v_{max} = 0,30$ м/с: высокая скорость, увеличивающая пропускную способность линии. На этом уровне возрастала вероятность размытости изображений из-за недостаточного времени прокатки, что снижало точность анализа.

Угол наклона α транспортной ленты (X_3) задавал динамику скатывания яблок под действием силы тяжести и влиял на равномерность их прокатки. Были выбраны три уровня:

– $\alpha_{min} = 5^\circ$: минимальный угол, обеспечивающий медленное движение плодов. На этом уровне уменьшались ошибки из-за скачков и резкого ускорения яблок.

– $\alpha_0 = 10^\circ$: стандартный угол, использовавшийся для большинства промышленных линий. Он обеспечивал баланс между скоростью прокатки и устойчивостью яблок.

– $\alpha_{max} = 15^\circ$: максимальный угол, увеличивающий скорость прокатки. На этом уровне повышалась вероятность нестабильного движения плодов, что влияло на точность фиксации камерой.

Варьирование угла наклона помогло определить оптимальные условия для обеспечения устойчивого движения яблок, особенно при работе с повреждёнными или нестандартными по форме плодами.

Каждый из выбранных факторов оказывал значительное влияние на ошибку $Loss$ и производительность Q системы. Разделение уровней варьирования позволило учесть широкий диапазон условий эксплуатации установки, что обеспечило универсальность системы при различных параметрах линии [60, 61].

Таким образом, параметры оптимизации системы в многофакторном эксперименте определяются системой:

$$\begin{cases} Loss = f(h, v, \alpha) \\ Q = f(h, v, \alpha) \end{cases} \quad (4.1)$$

Характеристиками плана эксперимента является минимальный ($h_{min}, v_{min}, \alpha_{min}$), основной (h_0, v_0, α_0) и максимальный ($h_{max}, v_{max}, \alpha_{max}$) уровни факторов, а также интервал их варьирования ($\Delta h, \Delta v, \Delta \alpha$) (рис. 4.2).

4.2 Применение метода теории планирования многофакторного эксперимента к исследованию системы сортировки

4.2.1 Применение многофакторного эксперимента

Метод теории планирования многофакторного эксперимента (ТПМЭ) основан на том, что исследуемую функцию $Y=f(X_1, X_2, \dots, X_n)$ можно разложить в ряд Тейлора:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \beta_{12} X_1 X_2 + \dots + \beta_{(n-1)n} X_{n-1} X_n + \beta_{11} X_1^2 + \beta_{22} X_2^2 + \dots + \beta_{nn} X_n^2, \quad (4.2)$$

где β_0 – значение функции отклика в начале координат $x_{01}, x_{02}, \dots, x_{0n}$;

$$\beta_i = \partial Y / \partial X_i; \beta_{ij} = \partial^2 Y / \partial X_i \partial X_j; \beta_{ii} = 0,5 \partial^2 Y / \partial X_i^2. \quad (4.3)$$

Выбранные факторы $X_1, X_2, \dots, X_n$ могут иметь и имеют разные порядки и размерность величин, что затрудняет вычисления. Поэтому в теории ПМФЭ для упрощения проведения экспериментальных исследований проводится

кодировка значений факторов, связь с натуральными величинами факторов которых определяется выражением [17,154]:

$$\bar{X}_i = (X_i - X_{0i}) / \Delta X_i, \quad (4.4)$$

где X_{0i} – исходный уровень i -го фактора; ΔX_i – интервал варьирования i -го фактора.

Исходный уровень X_{0i} i -го фактора определим из соотношения:

$$X_{0i} = (X_{i.min} + X_{i.max}) / 2, \quad (4.5)$$

где $X_{i.min}$, $X_{i.max}$ – значения минимального и максимального уровней факторов соответственно.

Интервал варьирования определяется по выражению:

$$\Delta X_i = X_{i.max} - X_{0i} = X_{0i} - X_{i.min}. \quad (4.6)$$

Значения максимального $\bar{X}_{i.max}$ и минимального $\bar{X}_{i.min}$ уровней фактора в кодированном виде [83,154,195]:

$$\bar{X}_{i.max} = (X_{i.max} - X_{0i}) / \Delta X_i = +1, \quad (4.7)$$

$$\bar{X}_{i.min} = (X_{0i} - X_{i.min}) / \Delta X_i = -1. \quad (4.8)$$

$$\bar{X}_{0i} = (X_{0i} - X_{0i}) / \Delta X_i = 0. \quad (4.9)$$

Максимальный, минимальный и исходный уровни факторов в кодированных величинах равны соответственно «+1», «-1» и «0». Интервал варьирования ΔX_i :

$$\Delta \bar{X}_i = \bar{X}_{i.max} - \bar{X}_{0i} = 1. \quad (4.10)$$

Запишем ряд Тейлора (4.2) в виде регрессионного уравнения, предварительно проведя кодирование факторов с учетом интервалов их варьирования:

$$Y = A_0 + A_1 \bar{X}_1 + A_2 \bar{X}_2 + \dots + A_n \bar{X}_n + A_{12} \bar{X}_1 \bar{X}_2 + \dots + A_{(n-1)n} \bar{X}_{n-1} \bar{X}_n + \\ + A_{11} \bar{X}_1^2 + A_{22} \bar{X}_2^2 + \dots + A_{nn} \bar{X}_n^2, \quad (4.11)$$

где A_0 , A_i , A_j , A_{ij} – коэффициенты регрессии.

Коэффициенты регрессии уравнения (4.11) определим с учетом рекомендаций:

$$A_0 = 1/m \sum_{j=1}^m Y_j - A_{11} / m \sum_{j=1}^m X_{ij}^2 - \dots - A_{uu} / m \sum_{j=1}^m X_{ju}^2 ; \quad (4.12)$$

$$A_i = \sum_{j=1}^m X_{ij} Y_j / \sum_{j=1}^m (X_{ij})^2, \quad (i \neq 1); \quad (4.13)$$

$$A_{iu} = \sum_{j=1}^m X_{ij} X_{uj} Y_j / \sum_{j=1}^m (X_{ij} X_{uj})^2, \quad (i \neq 1); \quad (4.14)$$

$$A_{ii} = \sum_{j=1}^m \left(X_{ij} - 1/m \sum_{j=1}^m X_{ij}^2 \right) Y_j / \sum_{j=1}^m \left(X_{ij}^2 - 1/m \sum_{j=1}^m X_{ij}^2 \right)^2, \quad (4.15)$$

где j, i – номер опыта и факторов.

Для проверки соответствия данных, полученных экспериментально, и значений теоретических исследований, проводят оценку адекватности полученного полинома с помощью доверительных интервалов. Наиболее показательным критерием оценки представляется критерий согласия Фишера:

$$K_{\phi p} = [\max(D_a; D_{cp})] / [\min(D_a; D_{cp})], \quad (4.16)$$

где D_a, D_{cp} – дисперсия адекватности и средних значений.

Дисперсия адекватности:

$$D_a = 1 / (m - b) \sum_1^m (Y_{i3} - Y_{ip})^2, \quad (4.17)$$

где Y_{i3}, Y_{ip} – средние значения измерений, полученные соответственно в ходе экспериментов и расчетов; b – количество коэффициентов регрессионного уравнения (4.11).

Дисперсию средних значений D_{cp} определим по выражению

$$D_{cp} = 1 / nm \sum_1^m (Y_i - \bar{Y})^2. \quad (4.18)$$

Уравнение регрессии (4.11) считается адекватным при

$$K_{\phi p} \leq K_{\phi m}, \quad (4.19)$$

где $K_{\phi m}$ – значение критерия Фишера, при заданном количестве степеней свободы q .

В каждой серии экспериментов проводилась регистрация динамических характеристик. Для обработки полученных кривых использованы

статистические методы обработки и анализа результатов экспериментов. При этом предполагалось, что все проведенные измерения независимы и равноточны, грубые и систематические ошибки устранены, имеют место лишь случайные ошибки с нормальным законом распределения. В первом приближении регистрация проводилась для шести периодических циклов в установившемся режиме срабатываний ЛЭМД. Было выявлено, что результаты отдельных наблюдений устойчивы и наибольшая погрешность определения значений регистрируемых параметров по результатам экспериментов не превышает 5%. Количество измерений, обеспечивающих заданную точность, выбрано равным пяти [62, 71].

4.2.2 Построение регрессионной модели $Loss\ f(h, v, \alpha)$

Как отмечалось в п.п. 4.1.2, наибольшее влияние на ошибку определения качества плодов влияет фактор h, α и v . При трех факторах и изменении их по трем уровням необходимо получить уравнение:

$$Loss = f(h, v, \alpha) \quad (4.20)$$

Пределы изменения факторов в данной задаче для некоторых частных применений выбраны на основе предварительных расчетов и результатов исследования [139] и охватывают диапазон значений, представляющих интерес при создании автоматизированных систем сортировки яблок:

$$\begin{cases} h = 0,27 \dots 0,55 \text{ м} \\ v = 0,1 \dots 0,3 \text{ м/с} \\ \alpha = 5^\circ \dots 15^\circ \end{cases} \quad (4.21)$$

Для определения влияния высоты h камеры, скорости v и угла α наклона транспортера при проведении исследований воспользуемся трехфакторным экспериментом. Решением данной задачи будет определение регрессионного уравнения (4.20), адекватное результатам экспериментальных исследований

Необходимо составить план эксперимента и определить его основные характеристики – верхний $X_{0i.max}$, нижний $X_{0i.min}$, исходный X_{0i} уровни факторов

(4.5), интервал варьирования ΔX_{0i} (4.6) и заменить нормированные значения их соответствующими кодированными величинами - $\bar{X}_{0i}$, $\bar{X}_{i.\max}$, $\bar{X}_{i.\min}$ (4.7), (4.8), (4.9), которые сведены в табл. 4.1

Табл.4.1 – План многофакторного эксперимента

Характеристика	Высота камеры, h, м	$\bar{X}_1$	Скорость транспортера, v, м/с	$\bar{X}_2$	Угол наклона транспортера, α , град	$\bar{X}_3$
Верхний уровень $h_{\max}, v_{\max}, \alpha_{\max}$	0,55	«+1»	0,3	«+1»	5	«+1»
Нижний уровень $h_{\min}, v_{\min}, \alpha_{\min}$	0,27	«-1»	0,1	«-1»	15	«-1»
Основной уровень h_0, v_0, α_0	0,41	«0»	0,2	«0»	10	«0»
Интервал варьирования, $\Delta h, \Delta v, \Delta \alpha$	0,14	–	0,1	–	5	–

Так как исследуемая зависимость (4.20) не является линейной, представим ее в виде квадратного полинома:

$$Y = A_0 + A_1 \bar{X}_1 + A_2 \bar{X}_2 + A_3 \bar{X}_3 + A_{11} \bar{X}_1^2 + A_{22} \bar{X}_2^2 + A_{33} \bar{X}_3^2 + A_{12} \bar{X}_1 \bar{X}_2 + A_{13} \bar{X}_1 \bar{X}_3 + A_{23} \bar{X}_2 \bar{X}_3, \quad (4.22)$$

где $A_0, A_1, A_2, A_3, A_{11}, A_{22}, A_{33}, A_{12}, A_{13}, A_{23}$ – коэффициенты регрессии.

Разработав методику проведения экспериментальных исследований, составим матрицу планирования трехфакторного эксперимента (табл.4.2), проведем анализ случайных погрешностей и оценим точность измерений.

Разброс полученных экспериментальных значений характеризуется дисперсией σ^2 и показателем вариации K_σ :

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y}_\sigma)^2}{n-1}}; \quad (4.23)$$

$$K_\sigma = \sigma / \bar{Y}, \quad (4.24)$$

где $\bar{Y}_\sigma$ – среднеарифметическое значение измерений; n – количество параллельных измерений в одной серии экспериментов.

Табл.4.2 – Матрица планирования трехфакторного эксперимента

Номер серии	$\bar{X}_1$	$\bar{X}_2$	$\bar{X}_3$	h, м	v, м/с	α , град	Loss, %				Урасч	Δy
							$y_{э1}$	$y_{э2}$	$y_{э3}$	$\bar{y}$		
1	–	–	–	0,27	0,1	5	40	50	50	46,7	43,4	3,3
2	+	–	–	0,55	0,1	5	0	10	0	3,33	2,2	1,13
3	–	+	–	0,27	0,3	5	50	40	40	43,3	37,6	5,7
4	+	+	–	0,55	0,3	5	40	40	30	36,7	36	0,7
5	–	–	+	0,27	0,1	15	80	70	70	73,3	63,6	9,7
6	+	–	+	0,55	0,1	15	10	20	10	13,3	14,8	1,5
7	–	+	+	0,27	0,3	15	40	50	40	43,3	44,6	1,3
8	+	+	+	0,55	0,3	15	50	50	40	46,7	39,8	6,9
9	0	0	0	0,41	0,2	10	20	10	10	13,3	5	8,3
10	+	0	0	0,55	0,3	10	20	20	30	23,3	14,7	8,6
11	–	0	0	0,27	0,1	10	40	30	30	33,3	31,9	1,4
12	0	+	0	0,41	0,2	10	0	10	0	3,33	13,3	9,97
13	0	–	0	0,41	0,2	10	10	20	10	13,3	3,7	9,6
14	0	0	+	0,41	0,2	15	10	20	20	16,7	22,9	6,2
15	0	0	–	0,41	0,2	5	0	0	10	3,33	10,9	7,57

Малые показатели коэффициента вариации K_v свидетельствуют о достоверности полученных результатов измерений. Так все данные, полученные экспериментальными исследованиями, лежат в пределах допустимых значений доверительных интервалов, определим для регрессионного уравнения (4.22) коэффициенты регрессии по (4.12) - (4.15) (табл. 4.3).

Табл.4.3. Значения коэффициентов регрессионного уравнения

A0	A1	A2	A3	A12	A13	A23	A11	A22	A33
	–12,6				–0,8	–3,3			

Тогда с учетом табл. 4.3 регрессионное уравнение для (4.20) запишем в виде:

$$Loss = 5 - 12,6 \bar{X}_1 + 4,8 \bar{X}_2 + 6 \bar{X}_3 + 11 \bar{X}_1 \bar{X}_2 - 0,8 \bar{X}_1 \bar{X}_3 - 3,3 \bar{X}_2 \bar{X}_3 + 14,3 \bar{X}_1^2 + 3,5 \bar{X}_2^2 + 11,9 \bar{X}_3^2 \quad (4.25)$$

Сравнение полученных по регрессионному уравнению (4.25) результатов со значениями экспериментальных исследований (табл. 4.2) $\bar{Y}$, показало, что максимальное расхождение $\Delta Y = \bar{Y} - Y_p$ лежит в допустимых пределах и составляет не более одной ошибки для каждой серии

экспериментов. Проведем проверку значимости коэффициента регрессии. С учетом рекомендаций [138, 139] влияние коэффициента $A_{13} = -0,8$ на функцию отклика лежит в пределах погрешности проведения эксперимента. Таким образом, незначимый коэффициент исключаем из рассмотрения, а уравнение (4.25) после упрощения примет вид:

$$Loss = 5 - 12,6 \bar{X}_1 + 4,8 \bar{X}_2 + 6 \bar{X}_3 + 11 \bar{X}_1 \bar{X}_2 - 3,3 \bar{X}_2 \bar{X}_3 + 14,3 \bar{X}_1^2 + 3,5 \bar{X}_2^2 + 11,9 \bar{X}_3^2 \quad (4.26)$$

Оценку соответствия результатов, полученных экспериментальными исследованиями и по регрессионному уравнению 4.26, проведем по критерию Фишера (4.16). Дисперсию адекватности D_a и средних значений D_{cp} определим по (4.17) и (4.18) соответственно. Основные результаты оценки проверки адекватности модели приведены в приложении 8. Анализ данных показало, что модель адекватна и может использоваться для оптимизации параметров системы с целью минимизации ошибки [63, 67].

Анализ коэффициентов регрессионного уравнения (4.26) позволяет оценить влияние каждого фактора и их взаимодействия на ошибку Loss. Чем больше абсолютное значение, тем сильнее влияние соответствующего фактора или взаимодействия [121, 122].

Рассмотрим линейные эффекты. Коэффициент $-12,6$ указывает на сильное отрицательное влияние на выходной параметр. Увеличение высоты камеры приводит к значительному снижению ошибки Loss. Это связано с улучшением общего обзора яблок. $A_2=4,8$ указывает на умеренное положительное влияние. Увеличение скорости ленты приводит к увеличению ошибки. Более высокая скорость может затруднять процесс идентификации дефектов. Коэффициент 6 демонстрирует умеренное положительное влияние. Увеличение угла наклона приводит к увеличению значения Loss. Это объясняется быстрым вращением и линейным перемещением, что создает размытость и усложняет определение дефектов [70, 83].

Проведем анализ эффектов взаимодействия. Значение $A_{12}=11$, показывает на сильное положительное влияние. Это означает, что совместное

увеличение высоты камеры и скорости ленты приводит к значительному увеличению ошибки Loss. При высокой скорости и высоте сложнее сфокусироваться и идентифицировать дефекты. Коэффициент $-3,3$ указывает на небольшое отрицательное влияние. Увеличение скорости ленты и угла наклона вместе приводит к небольшому уменьшению ошибки Loss [134, 135].

Так как уравнение (4.26) представляет собой нелинейную зависимость второго порядка, представляется важным провести оценку квадратичных эффектов. В частности, коэффициент $14,3$ демонстрирует сильное положительное влияние. Это указывает на то, что существует оптимальное значение высоты камеры, при котором ошибка Loss.

Значения коэффициентов $A_{22}=3,5$ и $A_{33}=11,9$ указывают на умеренное положительное влияние, что предполагает наличия оптимальных скорости ленты и угла наклона.




Рис.4.3. Поверхность отклика $Loss=f(h, \alpha)$ при $v = 0,1$ м/с (а); $v = 0,2$ м/с (б); $v = 0,3$ м/с (в)

На рис. 4.3 – рис. 4.5 показаны пространственные поверхности отклика исследуемой зависимости (4.26). Листинг кода для визуализации поверхностей отклика $Loss = f(h, v, \alpha)$ приведены в приложении 9.




Рис.4.4. Поверхность отклика $Loss=f(h, v)$ при $\alpha = 5^\circ$ (а); $\alpha = 15^\circ$ (б)




Рис.4.5. Поверхность отклика $Loss=f(v, \alpha)$ при $h = 270$ мм (а); $h = 410$ мм (б)

Анализ поверхностей отклика рис.4.3 – рис. 4.5 показал, что наименьшее значение ошибки Loss достигается, когда значение факторов $h = 410$; $v = 0,1$ м/с; $\alpha = 10^\circ$.

4.3 Оценка производительности линии сортировки

В п.п. 4.2 были представлены результаты экспериментальных исследований, позволившие определить регрессионную зависимость ошибки $Loss$ классификации дефектов яблок от высоты h камеры, скорости v и угла наклона α конвейера; определены оптимальные значения данных факторов, минимизирующие $Loss$, и позволяющие достичь наилучшего качества сортировки с точки зрения точности определения повреждений [79, 80].

Однако, помимо точности, критически важным аспектом является производительность Q сортировочной линии. Увеличение скорости обработки яблок при сохранении приемлемого уровня точности позволит существенно повысить экономическую эффективность предприятия. Таким образом, задача оптимизации системы технического зрения сводится не только к минимизации ошибки, но и к достижению баланса между значениями $Loss$ и Q . Необходимо учитывать, что параметры, оптимальные для минимизации ошибки классификации дефектов, могут не соответствовать оптимальным значениям для максимальной производительности линии. Поэтому, комплексное исследование влияния h , v , α на показатель Q является необходимым условием для успешного внедрения систем технического зрения в промышленное производство яблок [84, 109, 111].

Рассчитаем производительность Q по выражению:

$$Q = 3600 \cdot m_s \cdot v_\Sigma \cdot b, \quad (4.27)$$

где m_s – масса яблок на единицу площади транспортёра, $\text{м}/\text{м}^2$; v_Σ – результирующая скорость качения яблок с учётом скорости транспортера, $\text{м}/\text{с}$; b – ширина лотка ($b = 0,3$), м ; 3600 – перевод в секунды одного часа.

Из экспериментальных данных плотность плодов на ленте длиной $L = 1\text{м}$ составляет $n = 44$ шт. При массе одного яблока $m_{\text{я}} \approx 0,15$ кг, определим массу m_l плодов на единицу длины, $\text{т}/\text{м}$:

$$m_l = \frac{n \cdot m_{\text{я}}}{L} \quad (4.28)$$

Тогда

$$m_s = \frac{m_l}{b} \quad (4.29)$$

На скорость $V_{\text{я}}$ качения яблок влияет угол α наклона и скорость v транспортера. Для определения значения $V_{\text{я}}$ воспользуемся рисунком 4.6.




Рис. 4.6. Схема сил определения величины $V_{\text{я}}$

В основе теоретической модели лежит уравнение движения тела под действием силы тяжести F_T и силы трения качения $F_{\text{тр.кач.}}$. Сила тяжести:

$$F_T = m_{\text{я}}g, \quad (4.30)$$

где g – ускорение свободного падения, м/с^2 .

Представим компоненты силы тяжести вдоль транспортера F_{T_x} и перпендикулярная транспортеру F_{T_y} в виде:

$$\begin{cases} F_{T_x} = m_{\text{я}}g\sin\alpha \\ F_{T_y} = m_{\text{я}}g\cos\alpha, \end{cases} \quad (4.31)$$

где α – угол наклона транспортера (рис. 4.6)

Тогда с учетом (4.31) сила трения качения $F_{\text{тр.кач.}}$:

$$F_{\text{тр.кач.}} = M_{\text{тр}} \cdot F_{T_y} = M_{\text{тр}} \cdot m_{\text{я}} \cdot g \cdot \cos \cdot \alpha, \quad (4.32)$$

где $M_{\text{тр}}$ – коэффициент трения качения.

Оценить значения коэффициента $M_{\text{тр}}$ качения яблока по наклонному прорезиненному транспортеру достаточно сложная задача из-за его

зависимости от множества факторов, например, сорт и спелость плода, типа резины транспортера, его чистота, наличие протектора, влажности, температуры и др.

Определим $M_{тр}$ укрупненно исходя из рекомендаций [136, 157]. Рассмотрим диапазон значений коэффициента. Нижняя граница $M_{тр} = [0,005 - 0,1]$ предполагает идеальные условия, когда очень гладкое, сухое яблоко и чистая резина. Верхний диапазон $M_{тр} = [0,5 - 0,1]$, что соответствует влажному, шершавому яблоку и загрязненной резине. Тогда, учитывая сельскохозяйственное производство, наиболее вероятный диапазон для $M_{тр} = [0,02 - 0,07]$. Принимаем $M_{тр} = 0,05$.

По второму закону Ньютона уравнение движения:

$$m_я a = F_{T_x} - F_{тр.кач.}, \quad (4.33)$$

где a – ускорение яблока.

Подставим (4.31) и (4.32) в выражение (4.33) получим:

$$m_я a = m_я g \sin \alpha - M_{тр} \cdot m_я \cdot g \cdot \cos \cdot \alpha \quad (4.34)$$

Из уравнения (4.34) определим значение a :

$$a = g(\sin \alpha - M_{тр} \cdot \cos \cdot \alpha) \quad (4.35)$$

Для упрощения считаем, что плод начинает движение из состояния покоя, когда начальная скорость $V_0 = 0$, тогда:

$$V_я = a \cdot t, \quad (4.36)$$

где t – время, в течение которого происходит качение плода.

Определим расстояние L , которое прокатится яблоко за время t :

$$L = V_0 t + \frac{1}{2} a t^2,$$

или с учетом $V_0 = 0$

$$L = \frac{1}{2} a t^2 \quad (4.37)$$

Из (4.37):

$$t = \sqrt{\frac{2L}{a}} \quad (4.38)$$

Подставляя уравнение (4.38) в (4.36) и с учетом (4.35), получили:

$$V_{\text{я}} = a \cdot \sqrt{\frac{2L}{a}} = \sqrt{2 \cdot a \cdot L} = \sqrt{2 \cdot L \cdot g(\sin \alpha - M_{\text{тр}} \cdot \cos \alpha)} \quad (4.39)$$

Для обеспечения максимальной оценки поверхности плода в зоне действия камеры, движения транспортера направлено против качения плодов, тогда:

$$V_{\Sigma} = V_{\text{я}} - V_{\text{тр}} = \sqrt{2 \cdot L \cdot g(\sin \alpha - M_{\text{тр}} \cdot \cos \alpha)} - V \quad (4.40)$$

Подставим (4.28), (4.29) и (4.40) в выражения (4.27). Определим производительность от угла α наклона и скорости v транспортера:

$$Q = 3600 \cdot \frac{n \cdot m_{\text{я}}}{L} \cdot (\sqrt{2 \cdot L \cdot g(\sin \alpha - M_{\text{тр}} \cdot \cos \alpha)} - V) \quad (4.41)$$

Результат моделирования показан в виде поверхности отклика $Q = f(v, \alpha)$ по рис. 4.7




Рис.4.7. Результат моделирования зависимости $Q=f(v, \alpha)$

Таким образом оценка моделирования влияния указанных факторов на производительность (4.41) позволила определить значения v , α , обеспечивающие теоретически максимальную Q . Анализ поверхностей

отклика $Loss=f(h, v, \alpha)$ (рис.4.3 – рис.4.5) и $Q=f(v, \alpha)$ (рис.4.7) выявил выраженный компромисс между точностью и производительностью. Для достижения оптимального баланса между минимизацией ошибки классификации и максимизацией производительности предложено выделить область компромиссных решений [138, 139, 157]. Установлено, что оптимальный режим работы системы достигается при высоте камеры $h = 400$ мм, скорости $v=0,15$ м/с и угла наклона $\alpha=12^\circ$ транспортера, что обеспечивает ошибку классификации $Loss < 15\%$ и производительность Q не менее 2,5 т/ч. Это позволяет достичь приемлемого уровня точности при существенно более высокой производительности, чем при использовании параметров, оптимизированных только для минимизации $Loss$.

4.4 Выводы по четвертой главе

Создана экспериментальная модель системы, предназначенная для моделирования автоматизированной сортировки плодов. Установка позволяет изменять факторы, значимые для функционирования системы технического зрения и алгоритмов машинного обучения, а также обеспечивает сбор данных об основных характеристиках процесса.

Применение теории планирования многофакторного эксперимента позволило установить взаимосвязь между наиболее значимыми факторами системы технического зрения, такими как высота расположения камеры над объектом h , скорость перемещения v и угол наклона α транспортной ленты, и результирующими параметрами эффективности сортировки, в частности, величиной ошибки $Loss$ классификации дефектов и производительностью Q системы. По результатам проведенных экспериментов, на основе полученных данных, построена адекватная регрессионная модель, подтвержденная критерием Фишера, описывающая зависимость значения $Loss$ от варьируемых факторов системы технического зрения. Анализ коэффициентов регрессии позволил количественно оценить вклад каждого фактора и характер их

взаимодействия на величину ошибки, что позволило установить оптимальные значения параметров системы с учетом из влияния на величину Q .

ОБЩИЕ ВЫВОДЫ

В диссертации решена актуальная научно-практическая задача повышения эффективности процесса автоматизированной сортировки яблок на переработку с использованием алгоритмов нечёткой логики и интеллектуальных методов обработки изображений, позволяющая, в том числе, снизить уровень субъективности и потерь в процессе первичного отбора продукции.

Основные научные и практические результаты исследований состоят в следующем:

1. Разработана математическая модель, связывающая площадь повреждения плода с его предполагаемым объемом. Установлено, что аппроксимация плода сферой, а повреждения – средним между полусферой и сектором, позволяет получить адекватную оценку объема повреждения на основе площади дефекта. Проведенное сравнение с эмпирическими данными показало, что предложенная модель обеспечивает точность оценки объема повреждения с отклонением не более 15% при условии, что относительная площадь повреждения k_S не превышает 25.
2. Разработана модель нечеткой логики с приоритетной иерархией принятия решений для классификации яблок по категориям качества. Реализована процедура дефаззификации на основе модели Сугено нулевого порядка, преобразующая нечеткие выходные значения в конкретные управляющие сигналы, обеспечивающая адекватность работы системы, что подтверждается соответствием полученных выходных значений итоговым решениям об отнесении плодов к определенной категории качества.
3. Разработана и реализована алгоритмическое обеспечение и программная часть интеллектуальной автоматизированной системы сортировки яблок. Выбрана и обучена сверточная нейронная сеть *YOLOv11-seg* для решения задачи сегментации яблок и выделения областей повреждений. Достигнута точность масочной сегментации 0,967, что подтверждает высокую эффективность выбранной архитектуры для поставленной задачи.

4. Разработана методика и создана экспериментальная модель системы, предназначенная для моделирования автоматизированной сортировки плодов. Установка позволяет изменять факторы, значимые для функционирования системы технического зрения и алгоритмов машинного обучения, а также обеспечивает сбор данных об основных характеристиках процесса.
5. Для достижения оптимального баланса между минимизацией ошибки классификации и максимизацией производительности предложено выделить область компромиссных решений. Установлено, что оптимальный режим работы системы достигается при высоте камеры $h = 400$ мм, скорости $v=0,15$ м/с и угла наклона $\alpha=12^\circ$ транспортера, что обеспечивает ошибку классификации $Loss < 15\%$ и производительность Q не менее 2,5 т/ч. Это позволяет достичь приемлемого уровня точности при существенно более высокой производительности, чем при использовании параметров, оптимизированных только для минимизации $Loss$.

РЕКОМЕНДАЦИИ ПРОИЗВОДСТВУ

Для внедрения системы сортировки необходимо уделить внимание программной части: настройке базы данных, алгоритмов сегментации и правил нечёткой логики. Важным фактором является правильно организованное освещение, обеспечивающее стабильное качество изображений и точность классификации. Практическая реализация возможна на основе серийных камер, контроллеров и исполнительных механизмов.

ПЕРСПЕКТИВЫ ДАЛЬНЕЙШЕЙ РАЗРАБОТКИ ТЕМЫ

Перспективы связаны с адаптацией системы для сортировки других видов плодоовощной продукции и совершенствованием алгоритмов сегментации и классификации, что позволит повысить точность и расширить сферу применения.

Список литературы

1. Aloimonos J. Purposive and Qualitative Active Vision // Pattern Recognition: Proceedings of the 10th International Conference. – 1990. – Vol. 1. – P. 346–360.
2. Bennedsen B.S., Peterson D.L., Tabb A. Identifying apple surface defects using principal components analysis and artificial neural networks // Transactions of the ASABE. – 2007. – Vol. 50, No. 6. – P. 2257–2265.
3. Blasco J., Aleixos N., Moltó E. Machine vision system for automatic quality grading of fruit // Biosystems Engineering. 2003. Vol. 85, no. 4. P. 415–423.
4. Brady M. Intelligent Vision // AI in the 1980s and Beyond: An MIT Survey / Ed. by W.E.L. Grimson, R.S. Patil. – Cambridge (MA, USA): MIT Press, 1987. – P. 201–241.
5. Computer Vision: Applications of Visual AI and Image Processing / Ed. by P. Shukla, R. Aluvalu, S. Gite, U. Maheswari. – Berlin: Walter de Gruyter, 2023. – Vol. 15. – 370 p.
6. Dilek E., Dener M. Computer Vision Applications in Intelligent Transportation Systems: A Survey // Sensors. – 2023. – Vol. 23, № 6. – Article 2938. – 65 p.
7. Dobson J.E. Birth of Computer Vision. – Minneapolis: University of Minnesota Press, 2023. – 215 p.
8. Du Y., Zhang H., Liang L. et al. Applications of Machine Vision in Coal Mine Fully Mechanized Tunneling Faces: A Review // IEEE Access. – 2023. – Vol. 11. – P. 102871–102898.
9. Forsyth D.A., Ponce J. Computer Vision: A Modern Approach. 2nd ed. – Boston: Pearson Education, 2012. – xxix; 761 p.
10. Ganganagowdar N.V., Gundad A.V. An intelligent computer vision system for vegetables and fruits quality inspection using soft computing techniques // Agricultural Engineering International: CIGR Journal. – 2019. – Vol. 21, No. 3. – P. 171–178.

11. Huang T.S. Computer Vision: Evolution and Promise // Proceedings of the 1996 CERN School of Computing (Egmond aan Zee, Netherlands, 8–21 Sept. 1996). – Geneva: CERN, 1996. – P. 21–24.
12. Ji Q. Probabilistic Graphical Models for Computer Vision. – London: Elsevier, 2020. – xv; 278 p.
13. Khairullah K., Putra E.D. Identifikasi kematangan cabai menggunakan operasi morfologi (Opening dan Closing) dan Metode Backpropagation // Sistemasi. 2021. Vol. 10, no. 1. P. 96–105.
14. Li C., Heinemann P.H., Reed P.M. Genetic algorithms (GAs) and evolutionary strategy to optimize electronic nose sensor selection // Transactions of the ASABE. – 2008. – Vol. 51, No. 1. – P. 321–330.
15. Lin T.-Y. [et al.] Microsoft COCO: Common objects in context // Computer Vision – ECCV 2014: 13th European Conference, Zurich, Switzerland, Sept. 6–12, 2014: Proceedings. – Cham, 2014. – Pt. 5. – P. 740–755.
16. Long N.T.M., Thinh N.T. Using machine learning to grade the mango's quality based on external features captured by vision system // Applied Sciences. 2020. Vol. 10, no. 17. P. 5775.
17. Lu Y., Lu R. Development of a multispectral structured illumination reflectance imaging (SIRI) system and its application to bruise detection of apples // Transactions of the ASABE. – 2017. – Vol. 60, No. 4. – P. 1379–1389.
18. Luo K., Kong X., Zhang J. et al. Computer Vision-Based Bridge Inspection and Monitoring: A Review // Sensors. – 2023. – Vol. 23, № 18.
19. Marr D. Vision: A Computational Investigation into the Human Representation and Processing of Visual Information. – San Francisco: Freeman, 1982.
20. Mehl P.M. [et al.] Detection of defects on selected apple cultivars using hyperspectral and multispectral image analysis // Applied Engineering in Agriculture. – 2002. – Vol. 18, No. 2. – P. 219–226.
21. Nalbant K.G., Uyanık Ş. Computer Vision in the Metaverse // Journal of Metaverse. – 2021. – Vol. 1, № 1. – P. 9–12.

- 22.Nanni L., Ghidoni S., Brahnam S. Handcrafted vs. Non-Handcrafted Features for Computer Vision Classification // Pattern Recognition. – 2017. – Vol. 71, November. – P. 158–172.
- 23.Qi J., Ma L., Cui Z., Yu Y. et al. Computer Vision-Based Hand Gesture Recognition for Human-Robot Interaction: A Review // Complex & Intelligent Systems. – 2024. – Vol. 10. – P. 1581–1606.
- 24.Qin J., Lu R. Measurement of the optical properties of fruits and vegetables using spatially resolved hyperspectral diffuse reflectance imaging technique // Postharvest Biology and Technology. 2008. Vol. 49, no. 3. P. 355–365.
- 25.Rahman M., Liu H., Masri M. et al. A Railway Track Reconstruction Method Using Robotic Vision on a Mobile Manipulator: A Proposed Strategy // Computers in Industry. – 2023. – Vol. 148.
- 26.Roberts L.G. Machine Perception of 3D Solids // Optical and Electro-Optical Information Processing / Ed. by J.T. Tippett, L.C. Clapp. – Cambridge (MA, USA): MIT Press, 1965. – P. 159–197.
- 27.Scherer R. Computer Vision Methods for Fast Image Classification and Retrieval. – Cham (Switzerland): Springer Nature Switzerland, 2020. – ix; 137 p.
- 28.Siddique N.H., Adeli H. Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing. – Hoboken, NJ: Wiley, 2013. – 480 c
- 29.Sophokleous A., Christodoulou P., Doitsidis L., Chatzichristofis S.A. Computer Vision Meets Educational Robotics // Electronics. – 2021. – Vol. 10, № 6.
- 30.Абделхамид М.А., Судник Ю.А. Автоматический контроль зрелости томатов с помощью быстрой флуоресценции хлорофилла // Международный технико-экономический журнал. – 2022. – № 2.
- 31.Абделхамид М.А., Судник Ю.А. Технологические методы оценки зрелости томатов // Электротехнологии и электрооборудование в АПК. – 2020. – № 2(39). – С. 93–98.

32. Адлер Ю.П., Маркова Е.В., Грановский Ю.В. Планирование эксперимента при поиске оптимальных условий. – М.: Наука, 1976. – 278 с.
33. Аль-Офари А. А. Х. Х. Сортировка фруктов на основе технического зрения // Современное научное знание: теория, методология, практика: сб. науч. тр. XIII междунар. науч.-практ. конф., Смоленск, 27 апр. 2020 г. Смоленск: МНИЦ «Наукосфера», 2020. С. 55–59.
34. Балабанов П.В. [и др.] Роботизированный комплекс для сортировки яблок // Цифровизация агропромышленного комплекса: сб. науч. ст. II Междунар. науч.-практ. конф., Тамбов, 21–23 окт. 2020 г.: в 2 т. – Тамбов: Тамб. гос. техн. ун-т, 2020. – Т. 2. – С. 44–47.
35. Балабанов П.В., Дивин А.Г., Егоров А.С., Жиркова А.А. Система опико-электронной сортировки яблок на конвейере // Контроль. Диагностика. – 2022. – Т. 25, № 1(283). – С. 38–44.
36. Балабанов П.В., Жиркова А.А., Дивин А.Г., Егоров А.С., Мищенко С.В., Шишкина Г.В. Информационно-измерительная система для управления процессом сортировки овощей и фруктов // Вестник Тамбовского государственного технического университета. – 2022. – Т. 28, № 4. – С. 526–533.
37. Бараз В.Р., Пегашкин В.Ф. Использование MS Excel для анализа статистических данных: учеб. пособие. 2-е изд., перераб. и доп. – Нижний Тагил: НТИ (филиал) УрФУ, 2014. – 181 с.
38. Бахусова Е.В. Нечёткая математика для программистов: учебно-методическое пособие. – Тольятти: Филиал РГСУ в г. Тольятти, 2012. – 88 с.
39. Бекряев В.И. Основы теории эксперимента: учебное пособие. – СПб.: Изд-во РГГМУ, 2001. – 266 с.
40. Бессмертный И.А. Основы научных исследований в области информационных систем и технологий: учебник для вузов. – М.: Изд-во Юрайт, 2025. – 110 с. – (Высшее образование).

- 41.Благовещенская М. М. Информационные технологии систем управления технологическими процессами: учеб. пособие для вузов / М. М. Благовещенская, Л. А. Злобин/ – М.: Высш. шк., 2005. – 768 с.
- 42.Благовещенская М. М., Благовещенский И.Г., Назойкин Е.А. Методика автоматической оценки качества пищевых изделий на основе теории искусственных нейронных сетей // «Пищевая промышленность». 2015. №7.
- 43.Благовещенская М.М. Автоматика и автоматизация пищевых производств: Учебник для вузов / М.М. Благовещенская, Н.О Воронина, А.В. Казаков, И.К. Петров, Е.А. Прокофьев. – М.: Высш. шк., 1998. – 255 с.
- 44.Благовещенская М.М., Давыдова Г.Р., Семина Н.А., Благовещенский И.Г. Использование интеллектуальных технологий для контроля качества творога. // «Вестник Воронежского государственного университета инженерных технологий», №2, 2014. – с. 83 - 90.
- 45.Благовещенская М.М., Семина Н.А., Благовещенский И.Г., Савостин С.Д. Использование цифровой видеокамеры в качестве интеллектуального датчика системы автоматического регулирования процесса формирования гранулированных комбикормов. // «Вестник Воронежского государственного университета инженерных технологий», №2, 2014. – с. 48 – 55
- 46.Благовещенская М.М., Шаверин А.В., Благовещенский И.Г. Автоматизация контроля показателей вкуса шоколадных изделий на основе использования нейронных сетей // «Хранение и переработка сельскохозяйственного сырья». 2012. №8.
- 47.Благовещенский В. Г., Благовещенская М. М., Бесфамильная Е. М. Использование методов визуальной корреляции для анализа данных от различных источников // Цифровизация агропромышленного комплекса. Сборник научных статей. Тамбов. 21 – 23 октября 2020 Том I. 87-92 с.
- 48.Благовещенский В.Г., Крылова Л.А., Максимов А.С. Разработка программно-аппаратного комплекса мониторинга производства халвы.

- Книга - Развитие пищевой и перерабатывающей промышленности России: кадры и наука. 2017. С. 196-199.
- 49.Благовещенский И. Г. Использование системы компьютерного зрения для контроля в режиме онлайн качества сырья и готовой продукции пищевой промышленности // Пищевая промышленность. 2015. №6. С. 9–13
- 50.Благовещенский И. Г., Благовещенский В. Г., Назойкин Е. А., Петряков А. Н. Интеллектуальный анализ данных для систем поддержки принятия решений диагностики процессов производства пищевой продукции // Цифровизация агропромышленного комплекса. Сборник научных статей. Тамбов. 21 – 23 октября 2020 Том I. 105-110 с.
- 51.Благовещенский И.Г. Автоматизированная экспертная система контроля в потоке показателей качества помадных конфет с использованием нейросетевых технологий и систем компьютерного зрения: Автореф. дис. канд. техн. наук: 05.13.06. - М., 2015, - 26 с.
- 52.Благовещенский И.Г. Методологические основы создания экспертных систем контроля и прогнозирования качества пищевой продукции с использованием интеллектуальных технологий: Автореф. дис. докт. техн. наук: 05.13.06. - М., 2018, - 46 с.
- 53.Благовещенский И.Г., Благовещенская М.М., Апанасенко С.И. Создание виртуальных датчиков на основе нейронной сети для определения основных характеристик кондитерских масс. / И.Г. Благовещенский, М. М. Благовещенская, С.И. Апанасенко // «Кондитерское и хлебопекарное производство», №11 (154), 2014. – с. 37 - 41.
- 54.Благовещенский И.Г., Носенко С.М. Экспертная интеллектуальная система мониторинга процесса формования помадных конфет с использованием системы технического зрения // «Пищевая промышленность», №6, 2015. №6
- 55.Благовещенский И.Г., Троицкий А.К. Теоретические основы использования системы технического зрения в системе автоматического управления технологическими процессами //Материалы первой

- международной научно-практической конференции – выставки «Планирование и обеспечение подготовки и переподготовки кадров для отраслей пищевой промышленности и медицины». - М.: Издательский комплекс МГУПП, 2012. С. 165 – 172.
- 56.Благовещенский И.Г., Троицкий А.К. Формализация исходных изображений с целью выделения информации для обработки цифровых видеок кадров с использованием различных методов // Материалы первой международной научно-практической конференции – выставки «Планирование и обеспечение подготовки и переподготовки кадров для отраслей пищевой промышленности и медицины». - М.: Издательский комплекс МГУПП, 2012. С. 157 – 160.
- 57.Блохин В.Г., Глудкин О.П., Гуров А.И., Ханин М.А.; под ред. О.П. Глудкина. Современный эксперимент: подготовка, проведение, анализ результатов. – М.: Радио и связь, 1997. – 232 с.
- 58.Бобров В.П. Применение систем технического зрения // Механизация и автоматизация производства. – 1989. – № 9. – С. 23–25.
- 59.Бойко Н.Г., Устименко Т.А. Теория и методы инженерного эксперимента: курс лекций. – Донецк: ДонНТУ, 2009. – 158 с.
- 60.Болдин А.П., Максимов В.А. Основы научных исследований и УНИРС: учебное пособие. 2-е изд., перераб. и доп. – М.: Изд-во МАДИ, 2002. – 275 с.
- 61.Болдин А.П., Максимов В.А. Основы научных исследований: учебник для вузов. 2-е изд., перераб. и доп. – М.: Изд-во «Академия», 2014. – 352 с.
- 62.Бояршинова А.К., Фишер А.С. Теория инженерного эксперимента: текст лекций. – Челябинск: Изд-во ЮУрГУ, 2006. – 85 с.
- 63.Брылев А.А., Турчаева И.Н. Основы научно-исследовательской работы: учебник для вузов. – М.: Изд-во Юрайт, 2025. – 206 с.
- 64.Брылев А.А., Турчаева И.Н. Основы научно-исследовательской работы: учебник для среднего профессионального образования. – М.: Изд-во Юрайт, 2025. – 204 с.

- 65.Будаговская О.Н. Оптико-электронный контроль качества яблок: автореф. дис. ... канд. техн. наук: 05.20.02, 05.13.07. – М., 1993. – 24 с.
- 66.Бусаров Н.А. Сбор и товарная обработка плодов и ягод. – М.: Колос, 1970. – 247 с.
- 67.Вентцель Е.С. Теория вероятностей. 4-е изд. – М.: Наука, 1969. – 576 с.
- 68.Гордеев А.С. Автоматизированная обработка яблок: дис. ... д-ра техн. наук: 05.13.07. – М., 1996. – 423 л.
- 69.Горленко О.А., Борбаць Н.М., Можаяева Т.П. Дисперсионный анализ экспериментальных данных: учебник для вузов. 2-е изд., испр. и доп. – М.: Изд-во Юрайт, 2025. – 132 с.
- 70.Горленко О.А., Борбаць Н.М., Можаяева Т.П., Проскурин А.С. Основы теории эксперимента: учебник для среднего профессионального образования. 2-е изд., испр. и доп. – М.: Изд-во Юрайт, 2025. – 177 с.
- 71.Григорьева Д.Р., Гареева Г.А., Басыров Р.Р. Учебно-методическое пособие к практическим занятиям и лабораторным работам. – Набережные Челны: Изд-во НЧИ КФУ, 2018. – 42 с.
- 72.Гурьянов Д.В. Повышение эффективности сортирования яблок на основе цветных телевизионных датчиков: дис. ... канд. техн. наук: 05.20.02. – Мичуринск, 2004. – 199 л.
- 73.Гурьянов Д.В. Принципиальные основы построения телевизионных сортировочных автоматов для плодоовощной продукции // Вестник МГАУ. – Мичуринск, 2001. – Т. 1, № 4. – С. 82–88.
- 74.Гурьянов Д.В. Распознавание качества плодов // Робототехника в сельскохозяйственных технологиях: материалы Междунар. науч.-практ. конф., 10–12 нояб. 2014 г. – Мичуринск: Мичур. гос. аграр. ун-т, 2014. – С. 177–182.
- 75.Гурьянов Д.В., Гордеев А.С. Алгоритм анализа видеоинформации для сортировочных устройств // Высшая школа и проблемы научного обеспечения агропромышленного комплекса: материалы науч. конф. профессорско-преподавательского состава, аспирантов и сотрудников

- МГСХА, посвящённой 275-летию Российской академии наук. – Мичуринск, 1998. – Вып. 4.1. – С. 91–93.
- 76.Гурьянов Д.В., Гордеев А.С. Моделирование процесса распознавания качественного состояния поверхности продукции на базе цветных изображений // Вестник МГАУ. – Мичуринск, 2001. – Ч. 1, № 2. – С. 68–75.
- 77.Гурьянов Д.В., Гордеев А.С., Хмыров В.Д. Телевизионная система для исследования оптических характеристик поверхности сельскохозяйственной продукции // Вестник МГАУ. – Мичуринск, 2000. – Ч. 1, № 1. – С. 75–77.
- 78.Дивин А.Г., Балабанов П.В., Жиркова А.А., Мищенко С.В., Егоров А.С., Шишкина Г.В. Информационно-измерительная система для контроля яблок по размеру при их сортировке // Контроль. Диагностика. – 2023. – Т. 26, № 6. – С. 34–40.
- 79.Дрещинский В.А. Основы научных исследований: учебник для среднего профессионального образования. 2-е изд., перераб. и доп. – М.: Изд-во Юрайт, 2019. – 274 с.
- 80.Дрещинский В.А. Основы научных исследований: учебник для среднего профессионального образования. 3-е изд., перераб. и доп. – М.: Изд-во Юрайт, 2025. – 349 с.
- 81.Жиркова А.А., Балабанов П.В., Дивин А.Г. Автоматизированная система гиперспектрального контроля дефектов яблок // Современная наука: теория, методология, практика: материалы III Всерос. (нац.) науч.-практ. конф., Тамбов, 13–14 апр. 2021 г. – Тамбов: Тамб. гос. техн. ун-т, 2021. – С. 291–296.
- 82.Жиркова А.А., Балабанов П.В., Дивин А.Г. Выбор источников освещения при оптико-электронном контроле качества фруктов // Вестник Тамбовского государственного технического университета. – 2021. – Т. 27, № 4. – С. 536–542.
- 83.Зайдель А.Н. Погрешности измерений физических величин. – Л.: Наука, 1985. – 112 с.

84. Закин Я.Х., Рашидов Н.Р. Основы научных исследований. – Минск: Высш. шк., 1987. – 180 с.
85. Зеленова, Е. Н. Создание информационно-логической модели проектирования интеллектуальных систем управления / Е. Н. Зеленова, В. А. Каргин, М. М. Благовещенская // Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам для отраслей пищевой промышленности: сборник научных докладов V Международной конференции, Москва, 30 апреля 2024 года. – Курск: ЗАО «Университетская книга», 2024. – С. 162-170.
86. Исса, А. Повышение эффективности оценки качества мяса применением систем технического зрения и сверточных нейронных сетей / А. Исса, В. А. Каргин // Современные проблемы автоматизации технологических процессов и производств: сборник научных докладов научно-практической конференции с международным участием, посвященной 100-летию со дня рождения Игоря Константиновича Петрова, Москва, 11 октября 2023 года. – Курск: ЗАО «Университетская книга», 2023. – С. 201-204.
87. Казакевич П. П., Юрин А. Н. Разработка графического интерфейса приложения для системы технического зрения линии сортировки плодов // Инженерные технологии и системы. 2023. Т. 33, №3. С. 356–372
88. Казакевич П. П., Юрин А. Н., Микульский В. В., Прокопович Г. А., Ходасевич Л. А. Применение искусственной нейронной сети для идентификации качества яблок при сортировке // Агропанорама. 2023. №3(157). С. 31–38
89. Казакевич П. П., Юрин А. Н., Прокопович Г. А. Система технического зрения распознавания дефектов яблок: обоснование, разработка, испытание // Весці Нац. акад. навук Беларусі. Сер. аграр. навук. 2021. Т. 59, №4. С. 488–500
90. Казакевич П.П., Юрин А.Н., Прокопович Г.А. Система технического зрения распознавания дефектов яблок: обоснование, разработка, испытание

- // Весці Нацыянальнай акадэміі навук Беларусі. Сер. аграрных навук. – 2021. – Т. 59, № 4. – С. 488–500.
91. Кане М.Н. Основы научных исследований в технологии машиностроения. – Минск: Высш. шк., 1986. – 231 с.
92. Каргин В.А., Кишко В.В., Усанов К.М., Сохинов Д.Ю. Результаты создания интеллектуальной системы с использованием нейросетевых технологий для оценки качества яблок при сортировке // Вавиловские чтения – 2022: Сб. статей Междунар. науч.-практ. конф., посвящённой 135-летию со дня рождения акад. Н.И. Вавилова, Саратов, 22–25 ноября 2022 года. – Саратов: ООО «Амирит», 2022. – С. 710–715.
93. Каргин В.А., Кравченко Р.А., Кротов И.В., Резенов Е.Р. Рекомендации по реализации интеллектуальной системы определения качества колбасных изделий // Актуальные проблемы энергетики АПК: Материалы XIV Национальной научно-практической конференции с международным участием, Саратов, 28 апреля 2023 года / Под ред. С.М. Бакирова. – Саратов: Саратовский ГАУ им. Н.И. Вавилова, 2023. – С. 119–127.
94. Каргин В.А., Кравченко Р.А., Сохинов Д.Ю., Усанов К.М. Система интеллектуального контроля качества плодов в промышленном плодовоовощеводстве // Электротехнологии и электрооборудование в АПК. – 2025. – Т. 72, № 1(58). – С. 90–96.
95. Каргин В.А., Кротов И.В., Гданский Н.И. [и др.] Интеллектуальная автоматизированная система мониторинга засорения земель борщевиком Сосновского // Научно-технический вестник Поволжья. – 2024. – № 10. – С. 114–118.
96. Каргин В.А., Мокрушин С.А., Бикетов А.Р., Бею В.В. Рекомендации по разработке архитектуры нейронной сети для контроля уровня ликера в бутылке на этапе розлива // Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам для отраслей пищевой промышленности: Сб. науч. докладов IV Междунар. специализированной конф.-выставки,

- Москва, 26 апреля 2023 года. – М.: ФГБОУ ВО «РОСБИОТЕХ», 2023. – С. 225–229.
97. Каргин В.А., Мокрушин С.А., Усанов К.М., Охапкин С.И. Представление алгоритмов управления технологическими процессами в виде BPMN-диаграмм // Автоматизированные системы управления биотехнологическими процессами: Сб. науч. докладов Всерос. конф. с междунар. участием, Москва, 11 декабря 2024 года. – Курск: ЗАО «Университетская книга», 2025. – С. 208–213.
98. Каргин В.А., Сохинов Д.Ю., Кишко В.В., Каверзин И.В. Разработка и оценка нейронной сети для оценки качества яблок // Современные проблемы автоматизации технологических процессов и производств: Сб. науч. докладов науч.-практ. конф. с междунар. участием, посвящённой 100-летию со дня рождения И.К. Петрова, Москва, 11 октября 2023 года. – Курск: ЗАО «Университетская книга», 2023. – С. 205–211.
99. Каргин В.А., Сохинов Д.Ю., Кишко В.В., Сыч С.А. Оценка перспектив использования роботизированных систем для сортировки фруктов // Инновационное техническое обеспечение АПК: Материалы науч.-техн. конф. с междунар. участием им. А.Ф. Ульянова, Саратов, 3 октября 2023 года. – Саратов: Саратовский ГУГБиИ им. Н.И. Вавилова, 2023. – С. 308–313.
100. Каргин В.А., Сохинов Д.Ю., Усанов К.М. [и др.] Интеллектуальная автоматизированная система управления сортировкой фруктов // Электротехнологии и электрооборудование в АПК. – 2024. – Т. 71, № 2(55). – С. 100–106.
101. Каргин, В. А. Перспективы внедрения систем компьютерного зрения для оценки качества нанесения маркировки / В. А. Каргин, А. В. Щербаков // Современные проблемы автоматизации технологических процессов и производств: сборник научных докладов научно-практической конференции с международным участием, посвященной 100-летию со дня

- рождения Игоря Константиновича Петрова, Москва, 11 октября 2023 года.
– Курск: ЗАО «Университетская книга», 2023. – С. 212-216.
102. Каргин, В. А. Перспективы применения интеллектуальных управляющих систем для мониторинга яблоневых садов / В. А. Каргин, К. А. Абдуллаев, Е. А. Четвериков // Автоматизированные системы управления биотехнологическими процессами: сборник научных докладов Всероссийской конференции с международным участием, Москва, 11 декабря 2024 года. – Курск: ЗАО "Университетская книга", 2025. – С. 201-207.
103. Кирина М.В. [и др.] Применение методов люминесцентного анализа в системах технического зрения при сортировании плодов // Робототехника в сельскохозяйственных технологиях: материалы Междунар. науч.-практ. конф., 10–12 нояб. 2014 г. – Мичуринск: Мичур. гос. аграр. ун-т, 2014. – С. 188–191.
104. Кравченко Р.А., Бею В.В., Сохинов Д.Ю., Сармаев А.В. Выбор программируемых управляющих устройств для автоматизации процессов пищевого производства // Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам для отраслей пищевой промышленности: Сб. науч. докладов IV Междунар. специализированной конф.-выставки, Москва, 26 апреля 2023 года. – М.: ФГБОУ ВО «РОСБИОТЕХ», 2023. – С. 238–243.
105. Кузнецова Е.В. Математическое планирование эксперимента: учеб.-метод. пособие для студентов. – Пермь: Перм. гос. техн. ун-т, 2011. – 35 с.
106. Лакомов Д.В. Обработка изображений при распознавании образов сельскохозяйственной продукции // Цифровизация агропромышленного комплекса: сб. науч. ст. I Междунар. науч.-практ. конф., Тамбов, 10–12 окт. 2018 г.: в 2 т. – Тамбов: Тамб. гос. техн. ун-т, 2018. – Т. 1. – С. 261–263.
107. Леоненков А.В. Нечёткое моделирование в среде MATLAB и fuzzyTECH. – СПб.: БХВ-Петербург, 2005. – 736 с.

108. Люгер Д.Ф. Искусственный интеллект: стратегии и методы решения сложных проблем. 4-е изд., пер. с англ. – М.: Изд-во «Вильямс», 2003. – 268 с.
109. Ляшков В.И. Инженерный эксперимент: учеб. пособие. – Тамбов: ТГТУ, 2014. – 81 с.
110. Макаренко А.А. Алгоритмы и программная система классификации полутоновых изображений на основе нейронных сетей: автореф. дис. ... канд. техн. наук: 05.13.18. – М., 2007. – 22 с.
111. Макарова Н.В., Трофимец В.Я. Статистика в Excel: учебное пособие. – М.: Финансы и статистика, 2002. – 192 с.
112. Манжула В.Г., Федяшов Д.С. Нейронные сети Кохонена и нечеткие нейронные сети в интеллектуальном анализе данных. – М.: МИФИ, 2011. – 214 с.
113. Марголин Е. Методика обработки данных экспертного опроса // Полиграфия. – 2006. – № 5.
114. Маркелов К.С. Модель повышения информативности цифровых изображений на базе метода суперразрешения // Инженерный вестник. – М.: МГТУ им. Н.Э. Баумана, 2013. – № 3.
115. Марценюк М.А. Компьютерное зрение: учеб.-метод. пособие. – Пермь: ПГУ, 2007. – 204 с.
116. Маслов А.В. Структурно-механические характеристики пищевых продуктов: справочник. – М.: Легкая и пищевая промышленность, 1982. – 294 с.
117. Матвеев И.А., Трекин А.Н. Метод проекций яркости при поиске зрачка на изображении // Вестник ТГУ. Серия: Прикладная математика. – 2012. – № 4.
118. Матвеев И.А., Трекин А.Н. Поиск изображения по яркости предмета // Вестник ТГУ. Серия: Прикладная математика. – 2012. – № 5.

119. Матисон В.А., Еделев Д.А., Кантере В.М. Органолептический анализ продуктов питания: учебник. – М.: Изд-во РГАУ-МСХА им. К.А. Тимирязева, 2010. – 294 с.
120. Машины и аппараты пищевых производств: учебник для вузов. 2-е изд., перераб. и доп. – М.: КолосС, 2009. – 610 с.
121. Мидлтон М.Р. Анализ статистических данных с использованием Microsoft Excel для Office XP. – М.: БИНОМ. Лаборатория знаний, 2005. – 296 с.
122. Мокий М.С., Никифоров А.Л., Мокий В.С.; под ред. М.С. Мокия. Методология научных исследований: учебник для вузов. 3-е изд., перераб. и доп. – М.: Изд-во Юрайт, 2025. – 259 с.
123. Муаль М.Н., Козырев Д.В. Применение сверточных нейронных сетей для обнаружения и распознавания изображений на основании самописного генератора // Современные информационные технологии и ИТ-образование. 2022. Т. 18, № 3. С.
124. Мухачёв В.А. Планирование и обработка результатов эксперимента: учебное пособие. – Томск: Томский гос. ун-т систем управления и радиоэлектроники, 2007. – 118 с.
125. Никитина М.А. Интеграция цифровых технологий в процессе принятия решений при разработке пищевых продуктов заданного состава и свойств: дис. ... д-ра техн. наук. Москва: ФНИЦПС им. В.М. Горбатова, 2021. 45 с.
126. Новак В., Перфильева И., Мочкорж И. Математические принципы нечеткой логики = Mathematical Principles of Fuzzy Logic; пер. с англ. А.Н. Аверкина. – М.: ФИЗМАТЛИТ, 2006. – 347 с.
127. Пегат А. Нечеткое моделирование и управление. – М.: БИНОМ. Лаборатория знаний, 2009. – 798 с.
128. Родиков С.А. Некоторые особенности измерения твёрдости и плотности яблок при созревании // Хранение и переработка сельхозсырья. – 2002. – № 11. – С. 59–60.

129. Родиков С.А. Определение зрелости яблок // Хранение и переработка сельхозсырья. – 2007. – № 5. – С. 40–42.
130. Родиков С.А. Оценка степени загара яблок при хранении // Хранение и переработка сельхозсырья. – 2003. – № 9. – С. 69–70.
131. Родиков С.А. Экспресс-диагностика зрелости яблок // Садоводство и виноградарство. – 2001. – № 1. – С. 9–12.
132. Рудник Ю.А., Журавлев С.В. Робототехническая система для сортирования яблок // Робототехника в сельскохозяйственных технологиях: материалы Междунар. науч.-практ. конф., 10–12 нояб. 2014 г. – Мичуринск: Мичур. гос. аграр. ун-т, 2014. – С. 32–34.
133. Рутковский Л. Искусственные нейронные сети. Теория и практика. – М.: Горячая линия – Телеком, 2010. – 520 с.
134. Саати Т. Принятие решений при зависимостях и обратных связях: аналитические сети. – М.: Изд-во ЛКИ, 2008. – 360 с.
135. Саати Т. Принятие решений. Метод анализа иерархий. – М.: Радио и связь, 1989. – 316 с.
136. Саутин С.П. Планирование эксперимента в химии и химической технологии. – Л.: Химия, 1975. – 48 с.
137. Сигал Э. Практическая бизнес-статистика. – М.: Изд-во «Вильямс», 2002. – 1056 с.
138. Сидняев Н.И. Теория планирования эксперимента и анализ статистических данных: учеб. пособие для магистров. 2-е изд., перераб. и доп. – М.: Изд-во Юрайт, 2015. – 495 с. – Серия: Магистр.
139. Сидняев Н.И. Теория планирования эксперимента и анализ статистических данных: учебник и практикум для вузов. 2-е изд., перераб. и доп. – М.: Изд-во Юрайт, 2025. – 495 с.
140. Сохинов Д.Ю., Зудина Т.В., Тарола А.А., Пестова Е.В. Повышение эффективности процесса сортировки плодов применением алгоритмов нечеткой логики // Автоматизированные системы управления биотехнологическими процессами: Сб. науч. докладов Всерос. конф. с

- междунар. участием, Москва, 11 декабря 2024 года. – Курск: ЗАО «Университетская книга», 2025. – С. 309–313.
141. Сохинов Д.Ю., Кишко В.В., Каверзин И.В., Сармаев А.В. Анализ и выбор нейронной сети для оценки качества яблок // Современные проблемы автоматизации технологических процессов и производств: Сб. науч. докладов науч.-практ. конф. с междунар. участием, посвящённой 100-летию со дня рождения И.К. Петрова, Москва, 11 октября 2023 года. – Курск: ЗАО «Университетская книга», 2023. – С. 297–301.
142. Сохинов Д.Ю., Кравченко Р.А., Кишко В.В., Борисевский А.М. Основные рыночные решения искусственного интеллекта для реализации процесса обучения нейронных сетей // Интеллектуальные автоматизированные управляющие системы в биотехнологических процессах: Сб. докладов всерос. науч.-практ. конф., Москва, 29 марта 2023 года. – М.: РОСБИОТЕХ; ЗАО «Университетская книга», 2023. – С. 300–306.
143. Сохинов Д.Ю., Пестова Е.В., Тарола А.А., Зудина Т.В. Автоматизированная идентификация гнили яблок на основе технического зрения и глубокого обучения // Автоматизированные системы управления биотехнологическими процессами: Сб. науч. докладов Всерос. конф. с междунар. участием, Москва, 11 декабря 2024 года. – Курск: ЗАО «Университетская книга», 2025. – С. 313–317.
144. Сохинов Д.Ю., Сыч С.В., Тарола А.А., Зудина Т.В. Разработка интеллектуальной системы сортировки пищевой продукции на основе технического зрения и сверточных нейронных сетей // Проблемы и перспективы развития энергетики, робототехники и электротехнологий: Материалы Нац. науч.-практ. конф. с междунар. участием, Саратов, 23 декабря 2024 года. – Саратов: ФГБОУ ВО «Саратовский ГАУ им. Н.И. Вавилова», 2025. – С. 300–306.
145. Сохинов Д.Ю., Сыч С.В., Тарола А.А., Пестова Е.В. Автоматизация сортировки фруктов с использованием технического зрения и алгоритмов

- машинного обучения // Проблемы и перспективы развития энергетики, робототехники и электротехнологий: Материалы Нац. науч.-практ. конф. с междунар. участием, Саратов, 23 декабря 2024 года. – Саратов: ФГБОУ ВО «Саратовский ГАУ им. Н.И. Вавилова», 2025. – С. 294–300.
146. Сохинов Д.Ю., Тарола А.А., Зудина Т.В., Пестова Е.В. Анализ современных методов и технических средств для автоматизированной оценки качества плодов // Автоматизированные системы управления биотехнологическими процессами: Сб. науч. докладов Всерос. конф. с междунар. участием, Москва, 11 декабря 2024 года. – Курск: ЗАО «Университетская книга», 2025. – С. 317–321.
147. Сохинов Д.Ю., Тарола А.А., Зудина Т.В., Пестова Е.В. Программная реализация алгоритма управления процессом сортировки яблок // Автоматизированные системы управления биотехнологическими процессами: Сб. науч. докладов Всерос. конф. с междунар. участием, Москва, 11 декабря 2024 года. – Курск: ЗАО «Университетская книга», 2025. – С. 321–326.
148. Сохинов, Д. Ю. Анализ роботизированных систем для сортировки плодов на пищевом производстве / Д. Ю. Сохинов, Р. А. Кравченко, В. В. Кишко // Актуальные проблемы энергетики АПК: Материалы XIV Национальной научно-практической конференции с международным участием, Саратов, 28 апреля 2023 года / Под общей редакцией С.М. Бакирова. – Саратов: Саратовский государственный аграрный университет им. Н.И. Вавилова, 2023. – С. 271-277.
149. Сохинов, Д. Ю. Интеллектуальная система сортировки фруктов на базе технического зрения / Д. Ю. Сохинов // Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам для отраслей пищевой промышленности: сборник научных докладов V Международной конференции, Москва, 30 апреля 2024 года. – Курск: ЗАО «Университетская книга», 2024. – С. 313-318.


150. Сохинов, Д. Ю. Использование нейронной сети для сортировки и упаковки продукции пищевой промышленности / Д. Ю. Сохинов, С. А. Казарин, Е. Р. Резенов // Роговские чтения. Секция "Автоматизация технологических процессов и производств" : сборник докладов научно-практической конференции с международным участием, Москва, 30 ноября 2023 года. – Курск: Закрытое акционерное общество "Университетская книга", 2023. – С. 400-405.
151. Сохинов, Д. Ю. Методы оптимизации процесса сортировки яблок с использованием программных и аппаратных средств / Д. Ю. Сохинов, Е. В. Волинский, А. Р. Курбанов // Роговские чтения. Секция "Автоматизация технологических процессов и производств" : сборник докладов научно-практической конференции с международным участием, Москва, 30 ноября 2023 года. – Курск: Закрытое акционерное общество "Университетская книга", 2023. – С. 393-399.
152. Сохинов, Д. Ю. Нейро-нечеткий подход к классификации яблок с учетом внешних дефектов / Д. Ю. Сохинов // Автоматизированные системы управления биотехнологическими процессами: сборник научных докладов Всероссийской конференции с международным участием, Москва, 11 декабря 2024 года. – Курск: ЗАО "Университетская книга", 2025. – С. 299-303.
153. Сохинов, Д. Ю. Применение сверточных нейронных сетей в интеллектуальной системе сортировки фруктов / Д. Ю. Сохинов // Фабрика будущего: переход к передовым цифровым, интеллектуальным производственным технологиям, роботизированным системам для отраслей пищевой промышленности: сборник научных докладов V Международной конференции, Москва, 30 апреля 2024 года. – Курск: ЗАО «Университетская книга», 2024. – С. 318-323.
154. Сохинов, Д. Ю. Рекомендации по подготовке dataset для машинного обучения / Д. Ю. Сохинов, Р. А. Кравченко, О. В. Логачева // Роговские чтения: сборник докладов научно-практической конференции с

- международным участием, Москва, 16 декабря 2022 года. – Курск: Закрытое акционерное общество "Университетская книга", 2023. – С. 368-373.
155. Сохинов, Д. Ю. Роботизированные системы для сортировки фруктов в пищевой промышленности / Д. Ю. Сохинов, Р. А. Кравченко, И. В. Кротов // Повышение эффективной эксплуатации электрооборудования в сельском хозяйстве: Материалы I Национальной научно-практической конференции с международным участием имени Г.П. Ерошенко, Саратов, 22 декабря 2023 года. – Саратов: Саратовский государственный университет генетики, биотехнологии и инженерии имени Н.И. Вавилова, 2023. – С. 339-343.
156. Сохинов, Д. Ю. Экспериментальные исследования автоматизированной системы сортировки яблок на основе физической модели стенда / Д. Ю. Сохинов // Автоматизированные системы управления биотехнологическими процессами: сборник научных докладов Всероссийской конференции с международным участием, Москва, 11 декабря 2024 года. – Курск: ЗАО "Университетская книга", 2025. – С. 304-308.
157. Сохинов Д. Ю., Каргин В. А., Назойкин Е. А., Кравченко Р. А. Интеллектуальная управляющая система для косвенной оценки объема повреждения плодоовощной продукции // Инженерный вестник Дона. – 2025. – № 8. – URL: <http://ivdon.ru/ru/magazine/archive/n8y2025/10270> (дата обращения: 12.09.2025).
158. Судник Ю.А., Абделхамид М.А. Исследование медленной индукции флуоресценции хлорофилла для разделения плодов томатов по степени их зрелости // Электротехнологии и электрооборудование в АПК. – 2020. – № 3(40). – С. 109–114.
159. Судник Ю.А., Абделхамид М.А. Способ определения зрелости томатов на основе контроля их индукции флуоресценции хлорофилла // Вестник ФГБОУ ВПО «Московский государственный агроинженерный университет имени В.П. Горячкина». – 2020. – № 1(95). – С. 51–54.

160. Тадеусевич Р., Боровик Б., Гончаж Т., Леппер Б.; пер. И.Д. Рудинского. Элементарное введение в технологию нейронных сетей с примерами программ. – М.: Горячая линия – Телеком, 2011. – 408 с.
161. Терехов В.А., Ефимов Д.В., Тюкин И.Ю. Нейросетевые системы управления: учеб. пособие для вузов. – М.: Высш. шк., 2002. – 183 с.
162. Усков А.А. Системы с нечеткими моделями объектов управления: монография. – Смоленск: СФРУК, 2013. – 153 с.: ил.
163. Филин А.Д., Бестугин А.Р., Шатраков Ю.Г.; под науч. ред. А.Д. Филина. Методология научных исследований: учебник для вузов. – М.: Изд-во Юрайт, 2025. – 163 с.
164. Хайкин Е.Б. Построение аппроксимационных математических моделей в условиях обработки металлов давлением: учебное пособие. – Свердловск: УПИ, 1991. – 101 с.
165. Холян А.М., Рудницкий М.П. Введение в инженерное исследование. – Свердловск: УПИ, 1984. – 96 с.
166. Хорт Д.О. [и др.] Разработка алгоритмов системы распознавания ягод земляники садовой при роботизированном сборе // Электротехнологии и электрооборудование в АПК. – 2020. – № 1(38). – С. 133–141.
167. Чигорин А., Моисеев Б. Классификация автодорожных знаков на основе свёрточной нейросети, обученной на синтетических данных // ГрафиКон'2012: тр. 22-й Междунар. конф. по компьютерной графике и зрению, Москва, 1–5 окт. 2012 г. – М.: Моск. гос. ун-т, 2012. – С. 284–287.
168. Яблоков А. Е., Потапов С. А. Разработка устройства сортировки яблок по сортам с использованием технологий сверточных нейронных сетей // Изв. СПбГЭТУ «ЛЭТИ». 2024. Т. 17, № 6. С. 49-55
169. Яблоков А.Е., Благовещенский И.Г. Научно-практические основы создания автоматизированных систем технического мониторинга и диагностики оборудования зерноперерабатывающих предприятий на базе нейросетевых методов анализа данных. Москва: МГУПП, 2022. 221 с.

170. Яблоков А.Е., Жила Т.М. Применение СНС в вибродиагностике по спектрограммам и вейвлет-скалограммам сигнала // Известия Тульского государственного университета. Технические науки. 2021. № 12. С. 452–456.
171. Ярушкина Н.Г. Основы теории нечетких и гибридных систем: учеб. пособие для вузов. – М.: Финансы и статистика, 2004.
172. Яхьяева Г.Э. Нечеткие множества и нейронные сети: учебное пособие. 2-е изд., испр. – М.: Интернет-Ун-т Информ. Технологий; БИНОМ. Лаборатория знаний, 2012. – 315 с.

Экспериментальные исследования распространение гнили внутри
плодов







Фрагмент кода, реализующий алгоритм запуска захвата изображения

```

def initialize_camera():
    pass
def initialize_encoder():
    pass
def capture_image(fruit_id, angle_id):
    image = np.zeros((1080, 1920, 3), dtype=np.uint8)
    filename = f"{fruit_id}_angle{angle_id}.jpg"
    cv2.imwrite(filename, image)
    return filename
def verify_image(filepath):
    if not os.path.exists(filepath):
        return False
    if not filepath.endswith(".jpg"):
        return False
    if os.path.getsize(filepath) < 1000:
        return False
    return True
def save_images(fruit_id, images):
    verified = all(verify_image(img) for img in images)
    if verified:
        print(f"Плод {fruit_id}: все изображения сохранены корректно.")
    else:
        print(f"Плод {fruit_id}: ошибка при сохранении изображений.")
def conveyor_is_running(current_count, max_count):
    return current_count < max_count
def encoder_triggered():
    return True
def capture_fruit_images():
    initialize_camera()
    initialize_encoder()
    fruit_counter = 0
    max_fruits = 5
    while conveyor_is_running(fruit_counter, max_fruits):
        fruit_counter += 1
        fruit_id = f"Fruit_{fruit_counter}"
        images = []
        for angle_id in range(1, 4):
            if encoder_triggered():
                filename = capture_image(fruit_id, angle_id)
                images.append(filename)
                time.sleep(0.5)
        save_images(fruit_id, images)
capture_fruit_images()

```

Фрагмент кода, реализующий преобразования цветовой модели и поиска контура

```
# Загрузка изображения
image = cv2.imread('/content/Яблоко.jpg')
image_rgb = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)

# Преобразование изображения из RGB в HSV
image_hsv = cv2.cvtColor(image_rgb, cv2.COLOR_RGB2HSV)

# Выделение канала насыщенности (можно попробовать и другие)
s_channel = image_hsv[:, :, 1]

# Пороговая фильтрация для выделения плода
_, thresh = cv2.threshold(s_channel, 50, 255, cv2.THRESH_BINARY)

# Очистка шума с помощью морфологических операций
kernel = np.ones((5, 5), np.uint8)
thresh = cv2.morphologyEx(thresh, cv2.MORPH_CLOSE, kernel)

# Поиск контуров
contours, _ = cv2.findContours(thresh, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)

# Копия изображения для отрисовки контура
contour_image = image_rgb.copy()
cv2.drawContours(contour_image, contours, -1, (255, 0, 0), 2)

# Визуализация результатов
fig, axes = plt.subplots(1, 3, figsize=(18, 6))

axes[0].imshow(image_rgb)
axes[0].set_title('Исходное изображение')
axes[0].axis('off')

axes[1].imshow(thresh, cmap='gray')
axes[1].set_title('Пороговая маска')
axes[1].axis('off')

axes[2].imshow(contour_image)
axes[2].set_title('Выделение контура плода')
axes[2].axis('off')

plt.tight_layout()
plt.show()
```

Фрагмент кода для подключения модели СНС и установка порога доверия

```
import json
from tensorflow.keras.models import model_from_json

# Загрузка архитектуры модели из файла .json
with open('/content/model_structure.json', 'r') as json_file:
    model_json = json_file.read()

model = model_from_json(model_json)

# Загрузка весов модели из файла .h5
model.load_weights('/content/model_weights.h5')

# Компиляция модели (если требуется для работы валидации или метрик)
model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])

# Проверка структуры модели
model.summary()

# Установка порога доверия
confidence_threshold = 0.6 # Оптимальное значение, выбранное на валидационной выборке

# Функция для получения предсказаний с учётом порога доверия
def predict_with_threshold(model, image, threshold=confidence_threshold):
    prediction = model.predict(image)
    predicted_class = prediction.argmax(axis=1)
    confidence = prediction.max(axis=1)

    if confidence >= threshold:
        return predicted_class
    else:
        return None # Слишком низкая уверенность – классификация не производится
```

Фрагмент кода для сегментации и выделения области повреждения

```

# Загрузка изображения плода
image = cv2.imread('/content/Яблоко.jpg')
image_rgb = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
input_image = cv2.resize(image_rgb, (224, 224))
input_image = input_image / 255.0
input_image = np.expand_dims(input_image, axis=0)

# Загрузка обученной модели СНС
model = load_model('/content/fruit_damage_model.h5')

# Прогон изображения через модель
prediction = model.predict(input_image)

# Преобразование результата
predicted_mask = prediction[0, :, :, 0]

# Применение порога доверия
confidence_threshold = 0.6
binary_mask = (predicted_mask > confidence_threshold).astype(np.uint8) * 255

# Поиск контуров на бинарной маске
contours, _ = cv2.findContours(binary_mask, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)

# Копия изображения для визуализации
output_image = cv2.resize(image_rgb, (224, 224)).copy()

# Построение реальных контуров повреждений
for contour in contours:
    if cv2.contourArea(contour) > 50:
        cv2.drawContours(output_image, [contour], -1, (255, 0, 0), 1)

# Визуализация результатов
fig, axes = plt.subplots(1, 3, figsize=(18, 6))

axes[0].imshow(image_rgb)
axes[0].set_title('Исходное изображение')
axes[0].axis('off')

axes[1].imshow(binary_mask, cmap='gray')
axes[1].set_title('Бинарная маска повреждений')
axes[1].axis('off')

axes[2].imshow(output_image)
axes[2].set_title('Повреждения с реальными контурами')
axes[2].axis('off')

plt.tight_layout()
plt.show()

```

Фрагменты SQL-скрипта и ER-диаграммы структуры базы данных системы сортировки

```
CREATE TABLE batch (
  batch_id      BIGSERIAL PRIMARY KEY,
  received_at   TIMESTAMP NOT NULL,
  cultivar      TEXT,
  note          TEXT
);

CREATE TABLE apple (
  apple_id      BIGSERIAL PRIMARY KEY,
  batch_id      BIGINT NOT NULL REFERENCES batch(batch_id) ON DELETE CASCADE,
  track_uid     TEXT,
  created_at    TIMESTAMP NOT NULL DEFAULT now()
);

CREATE TABLE image (
  image_id      BIGSERIAL PRIMARY KEY,
  apple_id      BIGINT NOT NULL REFERENCES apple(apple_id) ON DELETE CASCADE,
  shot_ts       TIMESTAMP NOT NULL,
  path_original TEXT NOT NULL,
  width_px      INT,
  height_px     INT
);

CREATE TABLE detection (
  det_id        BIGSERIAL PRIMARY KEY,
  image_id      BIGINT NOT NULL REFERENCES image(image_id) ON DELETE CASCADE,
  mask_path     TEXT,
  bbox_x        INT,
  bbox_y        INT,
  bbox_w        INT,
  bbox_h        INT,
  area_px       INT,
  conf          NUMERIC(5,3)
);
```



Характеристики аппаратной части установки и методика экспериментальной проверки системы сортировки

В качестве основы системы технического зрения используется камера с высоким разрешением (1920×1200 пикселей), высокой частотой кадров (до 60 кадров в секунду) и возможностью работы в широком диапазоне условий освещения. Для обеспечения равномерного освещения используются светодиодные панели на базе *SMD*-модулей с регулируемой интенсивностью (до 8000 лк) и нейтральной цветовой температурой порядка 5000 К. Калибровка камеры проводится с использованием шахматной доски и программного обеспечения *OpenCV* (модуль *cv2.calibrateCamera*) для компенсации геометрических искажений и определения внутренних параметров камеры.

Конвейерная система построена на базе ленточного транспортера с регулируемой скоростью, оснащённого покрытием из матовой резины для мягкой прокатки плодов. Скорость конвейера регулируется в диапазоне от 0,10 до 0,30 м/с с помощью частотного преобразователя ВЕСПЕР Е2-MINI-SP25L. Для обеспечения равномерной подачи плодов используются индивидуальные посадочные ячейки и ограничители поперечного смещения, интегрированные с транспортной лентой.

Управление системой и обработка данных осуществляется с помощью персонального компьютера (*Intel Core i7-11700F*, 32 GB RAM, SSD 1 TB, GPU RTX 3080 Ti) под управлением операционной системы Windows 10. Программное обеспечение для управления системой разработано на языке Python 3.11 с использованием библиотек *OpenCV*, *NumPy*, *TensorFlow*, *scikit-image* и *pytcpool*. Обмен данными между ПК и ПЛК организован по протоколу *SLMP* (*Seamless Message Protocol*). Предобработка изображений, сегментация, расчёт повреждений и сортировка реализованы в виде взаимосвязанных модулей с поддержкой трекинга объектов в видеопотоке.

После обработки изображений и классификации плодов принимается решение о принадлежности каждого экземпляра к определённой категории качества. Для отбраковки дефектных плодов используется заслонки с позиционным приводом. Управление осуществляется через программируемый логический контроллер FX5U-32MR/ES с модулем FX5-40SSC, который обеспечивает точную синхронизацию движения конвейера и исполнительного устройства.

Для проведения экспериментов используются яблоки сорта «Голден Делишес», отобранные по критерию средней степени зрелости, однородности формы и отсутствия видимых повреждений. Для создания искусственных дефектов на части плодов наносятся повреждения, имитирующие пятна гнили, характерные для стадий порчи. Все плоды предварительно очищаются от загрязнений, просушиваются при комнатной температуре и калибруются по размеру и массе. Далее каждый плод последовательно подаётся в зону действия системы технического зрения на транспортной ленте. Это обеспечивает возможность анализа его состояния и проверки корректности принятия решений системой автоматической сортировки.

Листинг кода для проверки адекватности модели $Loss = f(h, v, \alpha)$

```

import numpy as np
import pandas as pd
import statsmodels.api as sm
from scipy.stats import f

data = {
    'h': [0.27, 0.55, 0.27, 0.55, 0.27, 0.55, 0.27, 0.55, 0.41, 0.55, 0.27, 0.41, 0.41, 0.41, 0.41],
    'v': [0.1, 0.1, 0.3, 0.3, 0.1, 0.1, 0.3, 0.3, 0.2, 0.3, 0.1, 0.2, 0.2, 0.2, 0.2],
    'alpha': [5, 5, 5, 5, 15, 15, 15, 15, 10, 10, 10, 10, 10, 15, 5],
    'Loss': [46.7, 3.33, 43.3, 36.7, 73.3, 13.3, 43.3, 46.7, 13.3, 23.3, 33.3, 3.33, 13.3, 16.7, 3.33]
}

df = pd.DataFrame(data)
# 2.2. Кодирование факторов
h_0 = 0.41
v_0 = 0.2
alpha_0 = 10
delta_h = 0.14      # (0.55 - 0.27) / 2
delta_v = 0.1       # (0.3 - 0.1) / 2
delta_alpha = 5     # (15 - 5) / 2
df['x1'] = (df['h'] - h_0) / delta_h
df['x2'] = (df['v'] - v_0) / delta_v
df['x3'] = (df['alpha'] - alpha_0) / delta_alpha
# 2.3. Построение регрессионного уравнения
# Добавим столбец с единицами для свободного члена
df['intercept'] = 1
# Выберем факторы для модели
independent_variables = ['x1', 'x2', 'x3', 'x1*x2', 'x1*x3', 'x2*x3', 'x1_sq', 'x2_sq', 'x3_sq', 'intercept']
# Создадим новые столбцы с произведениями факторов
df['x1*x2'] = df['x1'] * df['x2']
df['x1*x3'] = df['x1'] * df['x3']
df['x2*x3'] = df['x2'] * df['x3']
df['x1_sq'] = df['x1']**2
df['x2_sq'] = df['x2']**2
df['x3_sq'] = df['x3']**2
# Создадим матрицу X и вектор y
X = df[['x1', 'x2', 'x3', 'x1*x2', 'x1*x3', 'x2*x3', 'x1_sq', 'x2_sq', 'x3_sq', 'intercept']].values
y = df['Loss'].values
# 3. Расчет коэффициентов регрессии (МНК)
X_transpose = X.transpose()
X_transpose_X = np.matmul(X_transpose, X)
X_transpose_X_inverse = np.linalg.inv(X_transpose_X)
X_transpose_Y = np.matmul(X_transpose, y)
b = np.matmul(X_transpose_X_inverse, X_transpose_Y)
print("Коэффициенты регрессии (МНК):")
print(f"b0: {b[-1]:.4f}")
for i, coef in enumerate(b[:-1]):
    print(f"b{i+1}: {coef:.4f}")

```

```

# 4. Проверка адекватности модели (F-критерий)
# 4.1. Расчет предсказанных значений Loss
y_predicted = np.matmul(X, b)
# 4.2. Расчет SSE (Sum of Squares Error)
SSE = np.sum((y - y_predicted)**2)
# 4.3. Расчет SST (Total Sum of Squares)
SST = np.sum((y - np.mean(y))**2)
# 4.4. Расчет SSR (Sum of Squares Regression)
SSR = SST - SSE
# 4.5. Расчет степеней свободы
n = len(df)          # общее количество наблюдений
p = len(b) - 1       # количество параметров в модели, исключая константу
df_E = n - p         # степени свободы для ошибки
df_R = p              # степени свободы для регрессии
# 4.6. Расчет MSR и MSE
MSR = SSR / df_R
MSE = SSE / df_E
# 4.7. Расчет F-статистики
F_statistic = MSR / MSE
# 4.8. Расчет p-value
p_value = f.sf(F_statistic, df_R, df_E)
# 4.9. Вывод результатов
print("\nПроверка адекватности модели (F-критерий):")
print(f"SSE: {SSE:.2f}")
print(f"SST: {SST:.2f}")
print(f"SSR: {SSR:.2f}")
print(f"df_E: {df_E}")
print(f"df_R: {df_R}")
print(f"MSR: {MSR:.2f}")
print(f"MSE: {MSE:.2f}")
print(f"F-статистика: {F_statistic:.2f}")
print(f"p-value: {p_value:.3f}")
# 4.10. Анализ на адекватность
alpha = 0.05
if p_value < alpha:
    print("Модель адекватна (p-value < alpha)")
else:
    print("Модель неадекватна (p-value >= alpha)")

```

Листинг кода для визуализации поверхностей отклика $Loss = f(h, v, \alpha)$

```
import numpy as np
import matplotlib.pyplot as plt
from mpl_toolkits.mplot3d import Axes3D
# Регрессионное уравнение
def loss_function(x1, x2, x3):
    return 5 - 12.6*x1 + 4.8*x2 + 6*x3 + 11*x1*x2 - 0.8*x1*x3 - 3.3*x2*x3 + 14.3*x1**2 + 3.5*x2**2 + 11.9*x3**2
# Функция для перевода кодированных значений в абсолютные
def decode(x):
    height = x[0] * (550 - 270) / 2 + (550 + 270) / 2
    speed = x[1] * (0.3 - 0.1) / 2 + (0.3 + 0.1) / 2
    angle = x[2] * (15 - 5) / 2 + (15 + 5) / 2
    return height, speed, angle
# Уровни факторов (-1, 0, 1)
levels = [-1, 0, 1]
# Цикл по всем возможным комбинациям фиксированного фактора и его уровня
for fixed_factor in ['x1', 'x2', 'x3']:
    for fixed_level in levels:
        # Определяем, какие факторы будут меняться (x_var1, x_var2)
        if fixed_factor == 'x1':
            x_var1, x_var2 = 'x2', 'x3'
        elif fixed_factor == 'x2':
            x_var1, x_var2 = 'x1', 'x3'
        else: # fixed_factor == 'x3'
            x_var1, x_var2 = 'x1', 'x2'

        # Создаем сетку значений для изменяющихся факторов
        num_points = 50
        if x_var1 == 'x1':
            X_abs = np.linspace(270, 550, num_points) # Высота
        elif x_var1 == 'x2':
            X_abs = np.linspace(0.1, 0.3, num_points) # Скорость
        else:
            X_abs = np.linspace(5, 15, num_points) # Угол

        if x_var2 == 'x1':
            Y_abs = np.linspace(270, 550, num_points) # Высота
        elif x_var2 == 'x2':
            Y_abs = np.linspace(0.1, 0.3, num_points) # Скорость
        else:
            Y_abs = np.linspace(5, 15, num_points) # Угол

        X, Y = np.meshgrid(X_abs, Y_abs)
        # Вычисляем Loss в зависимости от того, какой фактор фиксирован
        Z = np.zeros_like(X)
        for i in range(X.shape[0]):
            for j in range(X.shape[1]):
                # Создаем массив со всеми тремя факторами
                factors = [0, 0, 0]
                # Заполняем значениями, соответствующими сетке
                if x_var1 == 'x1':
                    factors[0] = (X[i, j] - (550 + 270) / 2) / ((550 - 270) / 2)
                elif x_var1 == 'x2':
                    factors[1] = (X[i, j] - (0.3 + 0.1) / 2) / ((0.3 - 0.1) / 2)
                else:
                    factors[2] = (X[i, j] - (15 + 5) / 2) / ((15 - 5) / 2)
```

```

        if x_var2 == 'x1':
            factors[0] = (Y[i, j] - (550 + 270) / 2) / ((550 - 270) / 2)
        elif x_var2 == 'x2':
            factors[1] = (Y[i, j] - (0.3 + 0.1) / 2) / ((0.3 - 0.1) / 2)
        else:
            factors[2] = (Y[i, j] - (15 + 5) / 2) / ((15 - 5) / 2)
        # Устанавливаем фиксированный фактор
        if fixed_factor == 'x1':
            factors[0] = fixed_level
        elif fixed_factor == 'x2':
            factors[1] = fixed_level
        else:
            factors[2] = fixed_level
        # Вычисляем Loss
        Z[i, j] = np.abs(loss_function(factors[0], factors[1], factors[2]))
    # Строим поверхность
    fig = plt.figure(figsize=(10, 6))
    ax = fig.add_subplot(111, projection='3d')
    surf = ax.plot_surface(X, Y, Z, cmap='viridis')
    # Задаем подписи осей и заголовок
    if x_var1 == 'x1':
        ax.set_xlabel('Высота камеры (мм)')
    elif x_var1 == 'x2':
        ax.set_xlabel('Скорость ленты (м/с)')
    else:
        ax.set_xlabel('Угол наклона (градусы)')

    if x_var2 == 'x1':
        ax.set_ylabel('Высота камеры (мм)')
    elif x_var2 == 'x2':
        ax.set_ylabel('Скорость ленты (м/с)')
    else:
        ax.set_ylabel('Угол наклона (градусы)')
    ax.set_zlabel('Loss (abs)')
    # Get absolute value of the fixed variable
    fixed_values = [0,0,0]
    if fixed_factor == 'x1':
        fixed_values[0] = fixed_level
    elif fixed_factor == 'x2':
        fixed_values[1] = fixed_level
    else:
        fixed_values[2] = fixed_level
    fixed_value_abs = decode(fixed_values)[0] if fixed_factor == 'x1' else (decode(fixed_values)[1] if fixed_factor == 'x2' else decode(fixed_values)[2])
    ax.set_title(f'Loss vs {x_var1} и {x_var2} ( {fixed_factor} = {fixed_value_abs:.2f} {"мм" if fixed_factor=="x1" else ("м/с" if fixed_factor=="x2" else "градусы")} )')
    fig.colorbar(surf)
    plt.show()

```

АКТ
внедрения результатов работ, выполненных в рамках научно-
исследовательской и опытно-конструкторской деятельности

Результаты исследований Сохинова Дмитрия Юрьевича переданы в ООО «Русь», расположенное по адресу: Саратовская область г. Энгельс, проспект Строителей, 28, и использованы в работе производственной линии сортировки плодоовощной продукции, применяемой для подготовки сырья к переработке.

Внедрение заключалось в адаптации и использовании программных разработок автора, включающих алгоритмы выявления поверхностных дефектов и классификации плодов по качественным признакам. Программный код интегрирован в систему технического зрения предприятия и прошёл настройку с учётом специфики производственных условий, таких как уровень освещённости, высота установки камеры и скорость движения транспортёра.

Дополнительно были предоставлены методические рекомендации по выбору оптимальных параметров работы линии, что позволило стабилизировать процесс визуального контроля, снизить количество ошибок при определении дефектных плодов и повысить объективность сортировки.

Использование указанных решений обеспечило повышение эффективности подготовки сырья к переработке, сократило долю потерь и позволило перераспределить часть персонала с ручных операций на другие производственные процессы.

Заместитель руководителя предприятия: Косолапов В.П.





КРЕСТЬЯНСКОЕ(ФЕРМЕРСКОЕ)ХОЗЯЙСТВО«ХАМЗАТ»

366305, Чеченская Республика Шалинский муниципальный район с. Гурменчук пер. Гагарина дом 8., тел 7 938 00 74 74
АО «РоссельхозБанк», г. Грозный, Бик: 049690719., К/СЧ: 30101810600000000719 Р/СЧ: 40702810734060000320,

с.Гурменчук

09.09.2025г.

АКТ

о внедрении результатов научно-исследовательской работы

В производственные процессы предприятия КФХ «Хамзат» внедрены разработки Сохинова Дмитрия Юрьевича, связанные с созданием программного обеспечения.

Программный комплекс объединил несколько решений с целью выявления скрытых повреждений и интеллектуальной обработки данных, позволяющей вынести итоговое заключение о категории качества. Особое внимание уделено определению площади и прогнозированию объёма гнили, что ранее практически не учитывалось в промышленных условиях. Благодаря этому удалось перейти от поверхностной оценки к более глубокой диагностике состояния плодов.

Система не ограничивается фиксацией дефектов, а формирует итоговое решение с учётом совокупности признаков — от внешнего состояния поверхности до косвенных показателей возможных внутренних повреждений. Такой подход делает анализ более комплексным и позволяет снижать риск ошибочной сортировки даже в случаях, когда данные неоднозначны или противоречивы. Внедрение алгоритма повышает устойчивость работы линии при изменении условий эксплуатации, а также

рассматривается как важный элемент модернизации производственного процесса, закладывающий основу для его дальнейшего развития.

Практика использования показала, что применение программного решений позволило повысить надёжность визуального контроля, сократить влияние субъективных факторов и создать условия для дальнейшего расширения автоматизации сортировочного участка.

Руководитель предприятия

Зам. Главы



Исмаилов Х.З.

АКТ

внедрения результатов работ, выполненных в рамках научно-исследовательской и опытно-конструкторской деятельности

Результаты диссертационной работы Сохинова Дмитрия Юрьевича переданы в ООО «Агрос» (адрес: 412081, Саратовская область, Турковский район, село Рязанка, Вишнёвая ул., д. 90) и внедрены в производственную линию сортировки яблок, используемую для подготовки сырья к переработке в сок.

На основе разработанных алгоритмов нечеткой логики выполнена модернизация существующего сортировочного конвейера, включающая интеграцию модуля оптической инспекции с цифровой камерой высокого разрешения, а также внедрение специализированного программного комплекса, обеспечивающего автоматизированную классификацию плодов по степени зрелости и наличию повреждений.


Программный комплекс, реализующий алгоритмы обработки изображений, адаптирован под условия конкретной производственной площадки, включая вариации освещённости и скорости движения транспортёра, что позволило отказаться от сложных и дорогостоящих механических регулировок.

Внедрение технологии обеспечило значительное повышение точности сортировки, что привело к снижению потерь пригодного для переработки сырья, увеличению выхода готового продукта и сокращению затрат на ручной труд за счёт автоматизации визуального контроля. Эксплуатационные испытания показали устойчивую работу системы в условиях переменной загрузки линии, включая пики переработки в сезон массового сбора урожая.

По расчётам экономической службы предприятия, годовой экономический эффект от внедрения составит свыше 350 тыс. рублей, что обусловлено уменьшением объёмов списания сырья и снижением доли возвратов продукции по качественным показателям.

Дополнительно автоматизация сортировочного процесса позволила перераспределить задействованный на ручной сортировке персонал на другие технологические операции, что оптимизировало структуру производственных затрат, повысило эффективность использования трудовых ресурсов и обеспечило более равномерную загрузку работников в течение всего производственного цикла.

Руководитель предприятия

 Гуреханов Н.А./





«УТВЕРЖДАЮ»

Проректор по образовательной

деятельности

Даньшина О.А.

2025 г.

АКТ О ВНЕДРЕНИИ

в учебный процесс кафедры «Автоматизированные системы управления биотехнологическими процессами» ФГБОУ ВО «РОСБИОТЕХ» материалов диссертационной работы Сохинова Дмитрия Юрьевича по теме «Совершенствование процесса автоматизированной сортировки яблок применением интеллектуальной системы», представленной на соискание учёной степени кандидата технических наук по специальности 2.3.3 – Автоматизация и управление технологическими процессами и производствами

Мы, нижеподписавшиеся, заместитель директора института промышленной инженерии, информационных технологий и мехатроники, кандидат технических наук, доцент Назойкин Евгений Анатольевич, заведующий кафедрой АСУБП, Заслуженный деятель науки РФ, доктор технических наук, профессор Благовещенская Маргарита Михайловна, настоящим актом подтверждаем, что материалы диссертационной работы Сохинова Дмитрия Юрьевича, связанные с разработкой и исследованием алгоритмов технического зрения, методов анализа изображений и систем нечеткой логики для автоматизированной сортировки яблок, используются в учебном процессе, в лекционных курсах, при проведении лабораторных и практических занятий, в курсовом проектировании, при выполнении ВКР кафедры «Автоматизированные системы управления биотехнологическими процессами» при подготовке бакалавров направлений 15.03.04 «Автоматизация технологических процессов и производств», 15.03.06 «Мехатроника и робототехника», 27.03.04 «Управление в технических системах», а также магистров направлений 09.04.01 «Информатика и вычислительная техника» и 27.04.04 «Управление в технических системах», а именно:

- методика анализа цифровых изображений плодов и выделения областей повреждений;
- программные решения для оценки площади и прогнозирования объёма внутренних дефектов;
- подходы к применению нечеткой логики для классификации яблок по качественным категориям;

- рекомендации по выбору параметров работы сортировочных линий (высота камеры, угол освещённости, скорость транспортёра);
- примеры программного кода, реализующего алгоритмы обработки изображений и принятия решений;
- результаты экспериментальных исследований, иллюстрирующие эффективность использования методов технического зрения и интеллектуальных алгоритмов в условиях агропромышленного производства.

Указанные разработки включены в разделы следующих дисциплин: «Программирование и алгоритмизация»; «Системы искусственного интеллекта»; «Информационные системы и технологии»; «Интеллектуальные информационные системы»; «Автоматизация технологических процессов и производств»; «Программирование логических контроллеров».

Заместитель директора института ПИИТиМ,
кандидат технических наук, доцент

Назойкин
Евгений
Анатольевич

Заведующий кафедрой «Автоматизированные
системы управления биотехнологическими
процессами», доктор технических наук, профессор

Благовещенская
Маргарита
Михайловна

Подпись Назойкина Евгения Анатольевича и
Благовещенской Маргариты Михайловны заверяю

Ученый секретарь Ученого совета университета

Новикова
Жанна
Викторовна