

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
АМУРСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
(ФГБОУ ВО «АмГУ»)

Институт компьютерных и инженерных наук
Кафедра информационных и управляющих систем
Направление подготовки 09.04.04 – Программная инженерия
Направленность (профиль) образовательной программы Управление
разработкой программного обеспечения

ДОПУСТИТЬ К ЗАЩИТЕ
Зав. кафедрой

_____ А.В. Бушманов
« ____ » _____ 2025 г.

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

на тему: Проектирование и реализация алгоритма аппаратного
распознавания фруктов в условиях низкой освещенности

Исполнитель студент группы 3105-ом2	_____ (подпись, дата)	Ван Синь
Руководитель доцент, канд. техн. наук	_____ (подпись, дата)	А.В. Бушманов
Руководитель научного содержания программы магистратуры профессор, доктор техн. наук	_____ (подпись, дата)	И.Е. Ерёмин
Нормоконтроль инженер кафедры	_____ (подпись, дата)	В.Н. Адаменко
Рецензент доцент, канд. физ.-мат. наук	_____ (подпись, дата)	Д.В. Фомин

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
АМУРСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
(ФГБОУ ВО «АмГУ»)

Институт компьютерных и инженерных наук
Кафедра информационных и управляющих систем

УТВЕРЖДАЮ

Зав. кафедрой

_____ А.В. Бушманов

« ____ » _____ 2024 г.

З А Д А Н И Е

К магистерской диссертации студента группы 3105-ом2 Ван Синь

1. Тема магистерской диссертации: Проектирование и реализация алгоритма аппаратного распознавания фруктов в условиях низкой освещенности
(Утверждено приказом от 06.03.2025 № 609-уч)

2. Срок сдачи студентом законченной работы (проекта): 10.06.2025

3. Исходные данные к магистерской диссертации: документация разработчиков, интернет ресурсы, учебная литература

4. Содержание магистерской диссертации (перечень подлежащих разработке вопросов): Машинное обучение, проектирование алгоритма решения задачи, обучение модели по распознаванию фруктов и овощи при слабой освещенности

5. Перечень материалов приложения (наличие чертежей, таблиц, графиков, схем, программных продуктов, иллюстративного материала и т.п.):

6. Рецензент магистерской диссертации: Д.В. Фомин, доцент, канд. физ.-мат. наук

7. Дата выдачи задания 29.01.2024

Руководитель выпускной квалификационной работы: А.В. Бушманов, доцент, канд. техн. наук

(фамилия, имя, отчество, должность, уч.степень, уч.звание)

Заявление принял к исполнению _____

РЕФЕРАТ

Магистерская диссертация содержит 77 страница, 19 рисунок, 30 источников

АЛГОРИТМЫ ДЕТЕКЦИИ ОБЪЕКТОВ, РАСПОЗНАВАНИЕ СЕЛЬХОЗПРОДУКЦИИ, ГЛУБОКОЕ ОБУЧЕНИЕ, АНАЛИЗ ИЗОБРАЖЕНИЙ, КОМПЬЮТЕРНОЕ ЗРЕНИЕ

Основной целью данного исследования является разработка алгоритма детекции овощей и фруктов на основе глубокого обучения для точного распознавания множества категорий сельскохозяйственной продукции в сложных условиях. Проект направлен на применение передовых технологий

Процесс разработки алгоритма включал следующие ключевые этапы:

- проектирование и оптимизация модели на основе сверточных нейронных сетей;
- разработка и реализация облегченной схемы развертывания модели;
- тестирование производительности системы и настройка параметров.

Благодаря усовершенствованию и оптимизации алгоритмов серии YOLO была успешно создана система детекции овощей и фруктов с высокой точностью и производительностью в реальном времени. предлагая инновационные решения для автоматизированной сортировки и контроля качества сельскохозяйственной продукции.

СОДЕРЖАНИЕ

	5
Введение	
1 Технология обнаружения фруктов и овощей	6
1.1 Предыстория темы	10
1.2 История исследований и текущая ситуация	15
1.2.1 Анализ современного состояния зарубежных исследований	19
1.2.2 Анализ текущего статуса исследований в Китае	22
1.3 Техничко-экономическое обоснование эксплуатации	25
2 Проектирование и реализация системы	26
2.1 Алгоритм съемки при слабом освещении	30
2.1.1 Анализ экономической целесообразности	35
2.1.2 Трансферное обучение	37
2.2 Анализ функций программного обеспечения	40
2.2.1 Блок-схема системы	45
2.2.2 Модель нейронной сети классификации изображений	51
2.3 Характеристики алгоритма и аппаратной модели	53
3 Алгоритм обнаружения овощей и фруктов	58
3.1 Стадия разработки тестирования фруктов и овощей	65
3.1.1 Разработка алгоритма обнаружения	66
3.2 Тестирование программного обеспечения	72
Заключение	75
Библиографический список	77

ВВЕДЕНИЕ

В контексте развития национальной экономической и технологической трансформации то, как традиционные отрасли и сырьевые отрасли интегрируются с высокотехнологичными отраслями для достижения технологической трансформации, стало предметом озабоченности всего общества.

Среди них высокая добавленная стоимость в сельском хозяйстве и растущий производственный спрос фруктовой отрасли позволяют занять лидирующие позиции в промышленной трансформации. Однако в процессе сбора фруктов возникают такие проблемы, как низкая эффективность сбора и порча, вызванная экстремальными погодными условиями, из-за которых собирать фрукты становится слишком поздно.

В этом проекте будет использоваться технология обнаружения и сбора фруктов, основанная на технологии классификации изображений при освещении, через улучшение изображения при слабом освещении.

Сочетание технологии и технологии распознавания и классификации изображений позволяет идентифицировать спелые фрукты в условиях низкой освещенности (например, ночью, внезапный дождь и другие экстремальные погодные условия). Из-за высокой стоимости и сложности сбора наборов данных для обучения модели глубокого обучения план развития этого проекта является от малого к большому, от простого к сложному, начиная с исследований и экспериментов на одном типе фруктов, а затем проводя процесс реализации, оценка эффекта.

Путем запроса данных и исследований было обнаружено, что в Гуансийском автономном районе имеется обильное производство фруктов, среди которых цитрусовые занимают важное место. По этой причине в этой статье были собраны изображения путем ручного сбора для создания набора данных. Анализ большого количества экспериментальных

результатов показывает, что метод, описанный в этой, работа обеспечивает отличную производительность.

1 ТЕХНОЛОГИЯ ОБНАРУЖЕНИЯ ФРУКТОВ И ОВОЩЕЙ

1.1 Предыстория темы

На фоне слабого глобального экономического роста развитие традиционных обрабатывающих и сырьевых отраслей также в той или иной степени затруднено. Это препятствует экономическому развитию Гуанси, экономическое развитие которого в значительной степени зависит от сырьевой промышленности. Интеграция высоких технологий с традиционными первичными и вторичными отраслями для завершения качественной трансформации экономической модели стала следующим шагом в содействии экономическому развитию. Изучив книгу «Текущее состояние и тенденции развития индустрии переработки фруктов в Китае» узнали, что фруктовая промышленность Гуанси очень развита, и ее фруктовая промышленность вносит большой вклад в ВВП автономного региона.

Исследование по этой теме имеет следующие основные аспекты:

Гуанси расположен в тропических и субтропических регионах. Благодаря своему превосходному географическому положению, климатическим условиям, богатым природным ресурсам и обилию рабочей силы Гуанси имеет благоприятные условия для развития сельскохозяйственной промышленности. В частности, фруктовая промышленность стала движущая сила, важная отрасль экономического развития Гуанси. Кроме того, в Гуанси все еще есть бедные районы. Чтобы изучить методы и подходящие области для интеграции фруктовой отрасли с высокими и новыми технологиями, в этой статье было проведено детальное исследование рынка и обнаружена важная болевая проблема, а именно естественное гниение фруктов на деревьях из-за низкой эффективности сбора и нехватка времени из-за экстремальных погодных условий.

Брак, вызванный сбором.

Чтобы решить эту проблему, этот проект будет основан на технологии определения спелости фруктов при низкой освещенности посредством сочетания технологии распознавания и классификации изображений при низкой освещенности и технологии улучшения изображения при низкой освещенности, чтобы ее можно было обнаружить при низкой освещенности. (например, ночью и внезапные события). Идентификация и сбор спелых фруктов проводятся в экстремальных погодных условиях, таких как пасмурная и дождливая погода, чтобы повысить эффективность сбора и снизить экономические потери, вызванные естественными и неконтролируемыми факторами из-за длительного сбора. циклов и экстремальных погодных условий, тем самым увеличивая экономические выгоды фермеров, выращивающих фрукты. Технология обнаружения спелых фруктов стала эффективным способом повышения эффективности производства фруктовой отрасли и сокращения естественных потерь. Поэтому исследования в области технологии обнаружения спелых фруктов также стали основным направлением технических исследований по улучшению сельскохозяйственного производства, а также прямым и косвенным экономические выгоды, которые он генерирует, нельзя недооценивать.

1.2 История исследований и текущая ситуация

1.2.1 Анализ современного состояния зарубежных исследований

Зарубежные исследования: Исследования по технологии определения спелости фруктов были впервые инициированы зарубежными странами. После многих лет технологического развития эта область в основном разделена на две основные исследовательские идеи: разрушающий контроль и неразрушающий контроль. Среди них разрушающее тестирование в основном заключается в проведении серии выборочных тестов на pH, индекс растворимого сахара и твердость фруктов.

Этот тип метода имеет низкую стоимость реализации, но имеет проблему повреждения образцов фруктов, что затрудняет его проведение.

крупномасштабные коммерческие операции. На основе вышеизложенных проблем стихийно возникли методы исследования неразрушающим контролем. Ранние исследования этого типа метода в основном были сосредоточены на оптических, электрических, акустических и химических свойствах фруктов для проведения раннего неразрушающего контроля фруктов. С быстрым развитием технологий компьютерного зрения технология обнаружения спелых фруктов, основанная на компьютерном зрении, постепенно стала основным направлением исследований.

Цвигт Элар Рейер и др. использовали обнаружение повреждений качества фруктов на основе компьютерного зрения, и уровень успеха обнаружения достигал 65%. Благодаря бурному развитию технологий глубокого обучения производительность технологии обнаружения спелых фруктов, основанной на компьютерном зрении, продолжает улучшаться.




Рисунок 1 – Сегментные модули

Внутренние исследования: по сравнению с развитием зарубежной технологии обнаружения спелых фруктов, технология обнаружения спелых фруктов в моей стране началась поздно, и накопление технологий еще незрело. Однако, с непрерывным развитием отечественной экономики, науки и техники, отечественная технология обнаружения спелых фруктов Исследования быстро развивались, особенно в области исследований по

распознаванию спелых фруктов на основе компьютерного зрения, которые достигли уровня прогресса, сравнимого с уровнем развитых стран.

Среди них Ин Ибинь и др. использовали технологию компьютерного зрения для визуального определения зрелости образцов цитрусовых для проверки возможности метода машинного зрения. Индикаторами обнаружения являются соотношение твердых кислот цитрусовых и цвет их поверхности. Идентификация этого метода. Уровень успеха достиг поразительных. Е Цзиньтао и др. использовали модель прогнозирования цветовых характеристик, основанную на компьютерном зрении, для оценки плодов дыни «Золотая королева». Уровень успеха прогнозирования этого метода достиг. Это показывает, что метод классификации дынь разной степени зрелости на основе технологии машинного зрения возможен.

Технология обнаружения спелых фруктов, основанная на компьютерном зрении, имеет техническое преимущество, заключающееся в интеграции технологии глубокого обучения с методами обработки изображений, что делает метод высокоэффективным в распознавании, богатым функциями и неразрушающим для фруктов. В этом техническом методе в основном используются компьютеры и устройства получения изображений для моделирования зрительных функций человека, извлечения конкретной информации из изображений фруктов, такой как физиологические и биохимические характеристики фруктов, когда они созрели, а также обработки и анализа этих характеристик для определения их связи со зрелостью. корреляция между.

Модель нейронных сетей с низким уровнем освещенности изображений GLADNet. То есть глобальное световое восприятие и сохранение деталей в сети, дизайн модели в основном разделен на два этапа: Характеристика захвата и прогнозирования исходных изображений с низким уровнем освещенности, обработанных при выборке проб, путем разработки модели нейронной сети на основе структуры кодера - декодера, известной как глобальное прогнозирование освещенности.

Среди них узкий слой модели кодера - декодера имеет поле приема информации для достижения полного покрытия всего изображения. Разработка и обучение модели сети восстановления деталей с высокой способностью захвата деталей, которая дополняет детальную информацию, потерянную во время отбора проб вверх и вниз. Структура модели нейронной сети GLADNet показана на рисунке, и для фиксирования входного размера образца изображения на этапе глобальной оценки освещения вход отбирается до фиксированного размера. Затем для отображения входных изображений используется хорошо спроектированная сеть кодеров - декодеров. Прогнозирование глобального освещения изображений с помощью глобальной информации, получаемой через узкий слой. После проведения следующей операции отбора проб изображение было восстановлено до его первоначального размера для получения полного прогноза освещения.

После реализации операции прогнозирования освещения требуется реконструкция детальных характеристик изображения. В этом случае для детальной настройки прогнозов освещенности входного изображения используются несколько томов, в то время как детали различных процессов отбора проб изображения детализируются. Глобальная операция прогнозирования освещенности и детальная операция восстановления, структура этих двух этапов и функция потери подробно описаны:

Глобальная операция прогнозирования света делится на следующие три этапа: Размер входного исходного изображения с разрешением масштабируется с помощью следующей операции отбора проб, а размер изображения корректируется до $W_0 \times H_0$ с помощью ближайшей интерполяции соседей. Визуальное глобальное световое прогнозирование входных изображений с использованием специально разработанной сети кодеров - декодеров: затем отображение прогнозируемых визуальных характеристик осуществляется с использованием специально расположенных модулей отбора проб.

Количество блоков выборки, тщательно разработанных под W_0 и H_0 , позволяет узкому слою сетевой модели кодера - декодера принимать целые изображения для полного покрытия информации изображения. Эти структуры могут эффективно снизить потребность модели в пространстве для хранения, тем самым повышая операционную эффективность модели нейронной сети. В конце концов, используется многомерная симметричная операция отбора проб для получения профиля прогнозирования света с размером $W_0 \times h_0$.

Из-за проблем с размерной деформацией в разрешении характеристик изображения после глобального фотопрогнозирования необходимо масштабировать предсказанные характеристики, чтобы восстановить первоначальное разрешение изображения.

Подробная информация о восстановительных работах приводится ниже: Предыдущие операции были основаны на глобальных операциях по прогнозированию света. Но размер изображения изменяется при выборке вверх и вниз, что неизбежно приводит к потере некоторых деталей изображения.

Чтобы устранить этот недостаток, сеть разработала подробный набор деталей для восстановления рабочего процесса. Поскольку оригинальное входное изображение имеет более богатую визуальную информацию, чем визуальные характеристики, обработанные характеристиками, для этого детальная информация о оригинальных визуальных характеристиках может быть использована в качестве дополнения к характеристикам, что в конечном итоге приводит к улучшению с лучшими деталями.

Функция потерь: Процесс обучения модели оптимизирован с помощью вычислений нормы L_1 с использованием вычислений характерных потерь между минимизированным восстановлением изображения $F(X)$ и оригинальным реальным изображением Y . Затем для снижения уровня шума улучшенного изображения используется норма L_2 .

1.2.2 Анализ текущего статуса исследований в Китае

Из анализа состояния исследований технологии определения зрелости плодов на основе анализа машинного зрения видно, что исследования по определению зрелости плодов при нормальном освещении в этой технической области достигли хороших результатов, но обнаружение зрелости плодов при низкой освещенности дало хорошие результаты. добились хороших результатов.

Однако исследования в этой области всегда были относительно пустыми, и даже говорят, что в этой области почти никто не ступал. Этот проект является первым, в котором технология классификации изображений, основанная на низкой освещенности, сочетается с определением спелости фруктов. Технология, основанная на анализе машинного зрения.

Сочетание технологии распознавания и классификации изображений при освещении и робота-сборщика, разработанного этой проектной командой, позволяет идентифицировать и собирать спелые фрукты в условиях низкой освещенности (например, ночью, внезапный дождь и другие экстремальные погодные условия). чтобы решить проблему низкой эффективности сбора.

Это уменьшает естественную гниль плодов на дереве и проблему гнили, вызванную экстремальными погодными условиями, из-за которых сбор становится слишком поздно, и улучшает доходы фермеров, что также полностью отражает оригинальность проекта.

Этот проект объединяет технологию улучшения изображения при низкой освещенности и технологию классификации изображений в сквозном режиме для объединения сетей, а при нормальном освещении область исследований в области технологии обнаружения спелости фруктов стала насыщенной. поле, чтобы сделать практичность технологии и способность создавать ценность более выдающейся, что полностью отражает инновационный характер проекта.

Pytorch станет технической основой для обнаружения спелых фруктов при слабом освещении на основе глубокого обучения. Pytorch — это среда

разработки технологий глубокого обучения, основанная на языке программирования Python.

Он имеет функции проектирования и разработки модулей для глубоких нейронных сетей. В процессе обучения модели глубокой нейронной сети для предварительной обработки данных можно использовать метод проектирования признаков, предоставляемый Pytorch.

При разработке более сложных моделей нейронных сетей функциональные библиотеки, такие как numpy, часто комбинируются с Pytorch. Алгоритмы классификации изображений, основанные на глубоком обучении, являются важным направлением исследований в задачах компьютерного зрения.

Целью данного исследования является разработка высокопроизводительных моделей нейронных сетей для автоматического проектирования признаков и классификационного распознавания различных категорий изображений.

Метод классификации изображений, основанный на глубоком обучении, имеет преимущества в производительности, такие как высокая скорость распознавания и низкий уровень ошибок. По сравнению с традиционным методом классификации изображений машинного обучения, он имеет очевидные преимущества в производительности.

Благодаря высокой производительности алгоритма глубокого обучения, распознавание спелых плодов Алгоритм будет развиваться дальше, чтобы улучшить производительность модели и, наконец, интегрировать несколько моделей классификации изображений посредством ансамблевого обучения.

Алгоритм улучшения изображения при слабом освещении GLADNet, основанный на глубоком обучении, выполняет улучшение освещенности изображения и реконструкцию деталей на входных исходных данных изображения при слабом освещении.

Его принцип разделен на два этапа: первый шаг - создание сети визуального кодирования и декодирования для Исходное изображение при

слабом освещении используется для прогнозирования глобального освещения, чтобы получить глобальное представление визуальных функций. Второй шаг — построить реконструктор деталей на основе сверточной нейронной сети для восстановления деталей, потерянных при масштабировании изображения.

Распознавание речи в реальном времени.

Программная среда: Tensorflow-gpu-1.14.0 , Keras и операционная система Windows server2016; инструменты разработки: интегрированный набор инструментов Pycharm и conda; язык приложения – Python; архитектура: среда разработки глубокого обучения pytorch на основе языка Python для глубокой нейронной обработки Проектирование и реализация сети.

Таблица 1 - Сравнительная таблица

Критерий	Описание	Цветы	Птицы	Общее описание
Каталог товаров	Структура каталога	Раздел с цветами	Раздел с птицами	Общий каталог с фильтрацией
Управление запасами	Управление запасами товаров	Запасы цветов	Запасы птиц	Автообновление остатков, уведомления
Поиск товаров	Способы поиска товаров	По виду, цвету, цене	По виду, породе, цене	Расширенный поиск по фильтрам
Управление заказами	Обработка заказов	Доставка цветов	Доставка птиц	Единая система для всех заказов
Оплата	Методы оплаты	Онлайн, наложенный	Онлайн, наложенный	Общая платформа для всех оплат

Доставка	Способы доставки	По городу, курьером	По городу, курьером	Общие методы с учетом особенностей товаров
----------	------------------	---------------------	---------------------	--

1.3 Техничко-экономическое обоснование эксплуатации

После того, как модель глубокой нейронной сети успешно воспроизведена и достигает идеальных результатов производительности, необходимо провести технико-экономическое обоснование, чтобы определить, соответствует ли структура реализации модели идее построения модели, чувствительна ли модель к настройкам обучения. параметры и соответствует ли его надежность стандартам. Благодаря анализу модель, предложенная в этой статье, может успешно пройти три этапа обучения, проверки и тестирования и добиться превосходной производительности.

Это также осуществимо с эксплуатационной точки зрения. Чтобы решить проблему естественной гнили фруктов на деревьях из-за низкой эффективности сбора и гнили, вызванной экстремальными погодными условиями, когда собирать слишком поздно, в этом проекте будет использоваться технология обнаружения и сбора спелых фруктов, основанная на технологии классификации изображений при низких температурах.

Сочетание технологии распознавания и классификации изображений при освещении и робота-сборщика, мы проведем исследование по идентификации спелых фруктов при слабом освещении одного типа цитрусовых и оценим эффект от процесса реализации. Технология, используемая в этом проекте, может сыграть роль и в определенной степени помочь в решении этой болевой проблемы.

Исследовать и обсуждать преимущества и недостатки применения технологии обнаружения и сбора спелости фруктов на основе низкой освещенности. Тем самым улучшая и совершенствуя технологии.

Модель этого проекта представляет собой модель нейронной сети в режиме end-to-end, которая, как показано на рисунке 3, использует модель нейронной сети GLADNet для улучшения характеристик и извлечения характеристик исходных данных изображения при низкой освещенности, а затем частично перемещает три различные модели нейронной сети ResNet50, Inceptionv3 и Xception с помощью технологии обучения миграции, соответственно, чтобы обучить улучшенные характеристики изображения, создать набор характеристик с тремя наборами измерений и объединить эти три набора характеристик, передав полностью интегрированную нейронную сеть для обучения обнаружению зрелости изображения при низкой освещенности. Узнайте, созрели ли плоды и нужно ли их собирать.

Модель нейронной сети в режиме end - to - end, насколько это возможно, позволяет модели переходить от исходного ввода к конечному выходу, давая модели больше пространства, которое можно автоматически регулировать на основе данных, увеличивая общую совместимость модели, значительно упрощая сложность использования модели и улучшая ее простоту использования. Алгоритмический процесс проекта в основном делится на три этапа: улучшение низкой освещенности, глубокое извлечение визуальных характеристик на основе обучения миграции и распознавание классификации, алгоритмический процесс которого показан на рисунке

Улучшение низкой освещенности: На этом этапе используется модель нейронной сети GLADNet для улучшения освещенности и детализации входных исходных данных изображений с низкой освещенностью, которая делится на два этапа: первый шаг заключается в создании визуальной сети кодирования для глобального прогнозирования освещенности оригинальных изображений с низкой освещенностью, которые были отобраны для получения глобальных визуальных характеристик.

Второй шаг - построить детальный реконструктор на основе сверточной нейронной сети, чтобы восстановить детали, потерянные во

время масштабирования изображения. Глубокое извлечение визуальных характеристик на основе обучения миграции:

Для повышения точности распознавания спелых плодов в этой статье алгоритмические идеи обучения миграции переносят три модели нейронных сетей классификации изображений ResNet50, Inceptionv3 и Xception, предварительно обученные огромным количеством данных для конкретных задач.

И использовать интегрированные методы машинного обучения для интеграции визуальных характеристик, извлеченных из различных сетей классификации. Идентификация классификации: на основе вышеупомянутых двухэтапных задач, используя однослойный полный слой соединения и алгоритм вычисления вероятности классификации softmax для разработки сетевого модуля вычисления вероятности классификации, который изучает и вычисляет вероятность класса для характеристик, извлеченных и интегрированных с различными моделями сети классификации. Проверка зрелости изображения плодов при низкой освещенности позволяет определить, созревают ли плоды и нужно ли их собирать.

Модель нейронной сети в режиме end - to - end, насколько это возможно, позволяет модели переходить от исходного ввода к конечному выходу, давая модели больше пространства, которое можно автоматически регулировать на основе данных, увеличивая общую совместимость модели, значительно упрощая сложность использования модели и улучшая ее простоту использования.

2 ПРОЕКТИРОВАНИЕ ПРОГРАММНОГО ПРОДУКТА

2.1 Алгоритм съемки при слабом освещении

2.1.1 Анализ экономической целесообразности

Анализ осуществимости является основной задачей разработки модели программного обеспечения. Он играет жизненно важную роль на ранних этапах проектирования и разработки модели. Эта задача обычно выполняется до начала проектирования и разработки проекта.

Этот анализ в основном анализирует разработку программного обеспечения. Модель, осуществима ли она, и четко указывает на конкретные проблемы, которые возникнут в ходе конкретного процесса проектирования и разработки. Достаточно ли времени на разработку и средств на разработку. Может ли разработанное программное обеспечение решить практические задачи. Своевременно решать проблемы, обнаруженные в процессе анализа. Подробный анализ с технической точки зрения.

Техническая осуществимость модели программного обеспечения анализируется с уровня технических требований к разработке модели программного обеспечения. Этот этап является чрезвычайно важным проектом в полном процессе разработки программного обеспечения.

Можно ли действительно разработать модель программного обеспечения с использованием существующих технологий, главным образом, зависит от этого этапа зависит от фактического анализа. С этой целью модель нейронной сети в этой статье была полностью проанализирована с точки зрения анализа технической осуществимости.

Прежде всего, среда разработки глубокого обучения Pytorch стала одной из самых популярных сред разработки глубокого обучения. Его базовым языком является Python язык компьютерного программирования.

Этот язык стал наиболее используемым языком программирования в области глубокого обучения. Во-вторых, эффективное и удобное программное обеспечение для разработки также очень важно. В этом проекте

используется инструмент разработки проектов Pycharm для разработки программного обеспечения для моделей глубоких нейронных сетей. Инструмент настройки среды Anaconda стал первым выбором для этой статьи.

Его богатая библиотека программной среды и простота использования значительно ускоряют разработку модели, описанной в этой статье. Наконец, в этой статье в качестве компонентных моделей используются три модели классификации изображений: ResNet50, Inceptionv3 и Xception и интегрируются вышеуказанные модели с помощью алгоритма ансамблевого обучения. На практике обнаруживается, что эта идея осуществима. Следовательно, это осуществимо с точки зрения технической осуществимости.

Проанализируйте экономическую целесообразность программного обеспечения на основе финансирования, необходимого для разработки модели глубокой нейронной сети. Необходимо делать всеобъемлющие и подробные прогнозы по многим аспектам.

Средства, необходимые для нормальной разработки программного обеспечения для глубоких нейронных сетей, обычно включают следующие аспекты: доход разработчиков от их труда, плата за инструменты, используемые для разработки программного обеспечения, и выплата денежных средств после завершения разработки программного обеспечения, расходы, связанные с сопровождением и обновлением программного обеспечения и т. д. Эта система представляет собой небольшую разработку программного обеспечения для глубокой нейронной сети, во время реализации глубокой нейронной сети не требуется никаких дополнительных затрат, за исключением платы, необходимой для программных инструментов.

Стоимость полностью доступна для разработчиков, следовательно, эта система осуществима с точки зрения экономической целесообразности. Благодаря анализу модель, предложенная в этой статье, может успешно пройти три этапа обучения, проверки и тестирования и добиться

превосходной производительности. Это также осуществимо с эксплуатационной точки зрения.



Рисунок 2 – Диаграмма прецедентов

После того, как модель глубокой нейронной сети успешно воспроизведена и достигает идеальных результатов производительности, необходимо провести технико-экономическое обоснование, чтобы определить, соответствует ли структура реализации модели идее построения модели, чувствительна ли модель к настройкам обучения. параметры и соответствует ли его надежность стандартам. Благодаря анализу модель, предложенная в этой статье, может успешно пройти три этапа обучения, проверки и тестирования и добиться превосходной производительности. Это также осуществимо с эксплуатационной точки зрения.

Чтобы решить проблему естественной гнили фруктов на деревьях из-за низкой эффективности сбора и гнили, вызванной экстремальными погодными условиями, когда собирать слишком поздно, в этом проекте будет использоваться технология обнаружения и сбора спелых фруктов, основанная на технологии классификации изображений при низких температурах. Сочетание технологии распознавания и классификации

изображений при освещении и робота-сборщика, разработанного этой проектной группой, позволяет идентифицировать и собирать спелые фрукты в условиях низкой освещенности (например, ночью, внезапный дождь и другие экстремальные погодные условия). План исследований этого проекта - от малого к большому, от простого к сложному. Во-первых, мы проведем исследование по идентификации спелых фруктов при слабом освещении одного типа цитрусовых и оценим эффект от процесса реализации. Технология, используемая в этом проекте, может сыграть роль и в определенной степени помочь в решении этой болевой проблемы. Исследовать и обсуждать преимущества и недостатки применения технологии обнаружения и сбора спелости фруктов на основе низкой освещенности. Тем самым улучшая и совершенствуя технологии.

В повседневной жизни плохое освещение часто приводит к тому, что визуальные образцы, собранные оборудованием для сбора визуальной информации, имеют недостаточную интенсивность, плохую общую видимость и потерю деталей. Это напрямую влияет на эффективность оборудования для сбора визуальной информации. Чтобы решить вышеупомянутые проблемы, часто необходимо сначала улучшить визуальную информацию исходного изображения при слабом освещении.

Традиционный метод построения оптической физической модели ограничен ограничениями компонента отражения, что приводит к плохой способности для сбора и восстановления локальной подробной информации. В последние годы, благодаря постоянному развитию технологий глубокого обучения в задачах компьютерного зрения, визуальные алгоритмы, основанные на глубоких моделях, совершили прорыв во многих областях.

Точно так же метод улучшения изображения при слабом освещении, основанный на глубокой модели, эффективно решает вышеуказанные проблемы благодаря сильной способности сверточной нейронной сети захватывать локальную информацию. Например, Ло и др. ^[9] предложили

алгоритм улучшения изображений при слабом освещении с глубоким обучением, который использует гауссов процесс для поиска признаков.

Этот алгоритм использует обычную сверточную нейронную сеть для извлечения особенностей изображений при слабом освещении и, наконец, извлекает признаки с помощью богатые возможности. Особенности визуальной семантической информации используются для синтеза данных, чтобы лучше изучить семантическую связь между визуальными особенностями и пикселями изображения. Формула выглядит следующим образом, среди них $I_b(X)$ - улучшенное изображение.

На данный момент контраст освещения изображения является подходящим, а распределение интенсивности освещения также очень равномерным. $I_d(X)$ Это исходное изображение с низкой освещенностью, которое не было отсортировано алгоритмом улучшения. X – это визуальный признак, извлеченный сверточной нейронной сетью в образце изображения.

Блок или конкретный пиксель – $F()$ это оператор отображения освещения, который L определяется как функция, основанная на источнике света, и dsl представляет собой расстояние относительного положения между объектом в визуальном изображении. образец и соответствующий источник света.

В описанном выше процессе входное исходное изображение при слабом освещении $I_d(X)$ улучшается с помощью гауссова процесса для получения улучшенного изображения $I_b(X)$. Этот метод дополнительно повышает производительность модели улучшения изображения при слабом

Классификация изображений обычно относится к серии операций с объектами, выполняемых компьютером над исходным улучшением изображения изображением для окончательного получения векторного представления, богатого характеристиками категорий. Для выполнения проектирования признаков изображений, изображений, освещении и предоставляет ценный.

Эта задача является чрезвычайно важной задачей фундаментального исследования в задачах компьютерного зрения. Такие задачи обычно включают в себя два процесса: извлечение признаков и классификацию признаков. Традиционные методы извлечения признаков часто используют традиционные алгоритмы машинного обучения или функции, связанные с обработкой изображений, для выполнения проектирования признаков изображений, а затем классифицируют извлеченные визуальные признаки с помощью статистических методов.




Рисунок 3 – Диаграмма последовательности

Этот метод приводит к неспособности эффективно использовать потенциальную корреляцию между данными и невозможности получения эффективных глубоких визуальных функций. Благодаря большому успеху глубоких нейронных сетей в компьютерной области также широко предлагались алгоритмы классификации изображений на основе глубоких нейронных сетей.

2.1.2 Трансферное обучение

Среди них алгоритмы классификации изображений на основе сверточных нейронных сетей достигли оптимальной производительности в задачах классификации изображений. Многоуровневые сверточные

нейронные сети извлекают глубокие визуальные особенности, а возможности сверточных нейронных сетей по захвату пространственной информации еще больше улучшают возможности распознавания изображений.

Для извлеченных визуальных функций необходимо разработать классификатор для эффективной классификации изображения. Этот процесс часто включает в себя разработку эффективного алгоритма классификации для классификации и обучения классификатора изображений для дальнейшего повышения точности классификации модели. Ранние классификаторы изображений часто использовали алгоритм обратного распространения ошибки для обучения одноуровневых нейронных сетей.

Поскольку скрытый слой имеет только один слой, модель может легко соответствовать локальному оптимуму, что приводит к переобучению модели. Благодаря постоянному развитию компьютерного оборудования и вычислительной мощности, реализация моделей глубоких нейронных сетей стала возможной. Его многоуровневые скрытые слои могут предоставить модели более богатую потенциальную информацию.

Модель этого проекта представляет собой модель нейронной сети сквозного режима, как показано на рисунке. Эта модель использует модель нейронной сети GLADNet для улучшения и извлечения признаков из исходных данных изображения при слабом освещении. а затем с помощью технологии обучения миграции частично переносятся три разные модели нейронных сетей: ResNet50, Iinceptionv3 и Xception, чтобы обучить , чтобы обучить расширенные функции изображения соответственно, чтобы сгенерировать три набора наборов функций с размерностями и объединить эти три набора

Выполните объединение признаков и отправьте расширенные функции , Iinceptionv3 и Xception, чтобы обучить расширенные функции изображения соответственно, чтобы сгенерировать три набора наборов функций с размерностями и объединить эти три набора Выполните объединение признаков и отправьте объединенные признаки в полностью подключенную

нейронную сеть для обучения обнаружению зрелости изображений фруктов при низкой освещенности, чтобы определить, изображения соответственно модели изучать более ResNet50 , lncceptionv3 и Xception , чтобы обучить расширенные функции изображения соответственно, чтобы сгенерировать три набора наборов функций с размерностями и объединить эти три набора. Выполните объединение признаков и отправьте объединенные признаки в полностью подключенную нейронную сеть для обучения обнаружению зрелости изображений фруктов при низкой освещенности, чтобы определить, созрел ли плод и нужно ли его.




Рисунок 4 – Диаграмма состояния

ResNet50, lncceptionv3 и Xception , чтобы обучить расширенные функции изображения соответственно, чтобы сгенерировать три набора наборов функций с размерностями и объединить эти три набора.

Выполните объединение признаков и отправьте объединенные признаки в полностью подключенную нейронную сеть для обучения обнаружению зрелости изображений фруктов при низкой освещенности, чтобы определить, созрел ли плод и нужно ли его собирать.

Модель нейронной сети сквозного режима позволяет модели максимально перемещаться от исходных входных данных к конечному выводу, предоставляя модели больше места для автоматической настройки в соответствии с данными, что значительно повышает общую пригодность модели. упрощение использования модели и повышение ее простоты использования. Алгоритм этого проекта в основном разделен на три этапа

Улучшение при слабом освещении: на этом этапе используется модель нейронной сети улучшения изображения при слабом освещении GLADNet для улучшения освещенности изображения и детальной реконструкции на входных исходных данных изображения при слабом освещении.

Принцип разделен на два этапа: первый шаг - построить сеть визуального кодирования и декодирования. Исходное изображение при слабом освещении, которое было подвергнуто субдискретизации, используется для прогнозирования глобального освещения для получения глобального представления визуальных функций. Второй шаг — построить реконструктор деталей на основе сверточной нейронной сети для восстановления деталей, потерянных при масштабировании изображения.

2.2 Анализ функций программного обеспечения


2.2.1 Блок-схема системы

Глубокое извлечение визуальных признаков на основе трансферного обучения. Чтобы повысить точность классификации и распознавания спелых фруктов, в этой статье используется идея разработки алгоритма трансферного обучения для специальной разработки трех моделей нейронных сетей классификации изображений ResNet50, Inceptionv3 и Xception, которые были предварительно обучены на массивных данных. А метод ансамблевого

обучения машинного обучения используется для объединения визуальных признаков, извлеченных различными классификационными сетями.

Распознавание классификации: на основе вышеуказанных двухэтапных задач для объединения используется один слой полностью связанного слоя и алгоритм расчета вероятности классификации softmax. Изучаются особенности и рассчитываются вероятности классов. Обнаружить зрелость плодов на изображениях при слабом освещении, определить, созрел ли плод и нужно ли его собирать.

Модель нейронной сети сквозного режима позволяет модели максимально перемещаться от исходных входных данных к конечному выводу, предоставляя модели больше места для автоматической настройки в соответствии с данными, что значительно повышает общую пригодность модели. упрощение использования модели и повышение ее простоты использования.



```
(root@kali) - [~/Desktop/python_work]
# cd /root/Desktop/python_work ; /usr/bin/env /bin/python /root/.vscode-oss/extensions/ms
-python.python-2024.2.1-universal/pythonFiles/lib/python/debugpy/adapter/../../debugpy/launc
her 50907 -- /root/Desktop/python_work/magicians.py
alice
david
carolina
-----1-----
Alice,that was great trick!
David,that was great trick!
Carolina,that was great trick!
-----2-----
Alice,that was great trick!
I can't wait to see your ,Alice.

David,that was great trick!
I can't wait to see your ,David.

Carolina,that was great trick!
I can't wait to see your ,Carolina.

-----3-----
Alice,that was great trick!
I can't wait to see your ,Alice.

David,that was great trick!
I can't wait to see your ,David.

Carolina,that was great trick!
I can't wait to see your ,Carolina.

Thank you,everyone.That was a great magic show!
-----4-----
(root@kali) - [~/Desktop/python_work]
```

Рисунок 5 – Создать заказ

2.2.2 Модель нейронной сети классификации изображений

Алгоритмический процесс этого проекта в основном разделен на обработку улучшения входного изображения при слабом освещении для получения изображения при нормальном освещении и миграцию задач предварительно обученных моделей ResNet50, Inceptionv3 и Xception с помощью алгоритма трансферного обучения. на улучшенном изображении. Существует три этапа извлечения визуальных признаков глубокого уровня и, наконец, классификации и идентификации извлеченных признаков. Блок-схема системы показана на рисунке

GLADNet , то есть сети глобальной осведомленности об освещении и сохранения деталей, разработка этой модели в основном разделена на два этапа:

- 1) Путем разработки модели нейронной сети на основе структуры кодер-декодер для захвата и прогнозирования особенностей исходного изображения при слабом освещении, которое было подвергнуто субдискретизации, этот этап называется прогнозированием глобального освещения. Среди них есть поле приема информации на узком уровне модели кодера-декодера для достижения полного охвата всего изображения. В это время несколько сверточных слоев используются для настройки деталей прогнозирования освещения особенностей входного изображения, и в то же время подробная информация о различных процессах выборки изображения подробно дополняется, заключается в разработке и обучении сетевой модели детальной реконструкции с возможностью высокой детализации путем дополнения




Рисунок 6 – библиотека импорта

2.3 Характеристики алгоритма и аппаратной модели

Чтобы зафиксировать входной размер выборки изображения на этапе оценки глобального освещения, входные данные субдискретизируются до фиксированного размера. Затем разработанная сеть кодера-декодера используется для выполнения операций сопоставления признаков входного изображения. Прогнозируйте глобальное освещение изображения с помощью глобальной информации, полученной узким слоем. После операции понижения разрешения изображение восстанавливается до исходного размера, чтобы получить полный прогноз освещения. После реализации операции прогнозирования освещенности необходимо восстановить детализацию изображения. В это время несколько сверточных слоев используются для настройки деталей прогнозирования освещения особенностей входного изображения, и в то же время подробная информация о различных процессах выборки изображения подробно дополняется. Подробно объяснены операция прогнозирования глобального освещения и

операция детальной реконструкции, структура этих двух шагов и функция потерь:

Операция прогнозирования глобального освещения в основном делится на следующие три этапа.

Входное исходное изображение масштабируется по разрешению посредством операции понижающей дискретизации, а размер изображения корректируется до $W_0 \times H_0$ с использованием интерполяции ближайшего соседа.

Специально разработанная сеть кодера-декодера используется для прогнозирования визуального глобального освещения на входном изображении: затем используется специально организованный модуль каскадной выборки для выполнения сопоставления признаков с предсказанными визуальными признаками. Количество блоков понижающей дискретизации тщательно рассчитывается в соответствии с W_0 и H_0

Чтобы узкий уровень сетевой модели кодера-декодера мог принимать все изображение для достижения полного охвата информации изображения. Вышеупомянутая структура может эффективно снизить потребность модели в пространстве для хранения, тем самым повышая эффективность вычислений модели нейронной сети. Наконец, операция симметричной повышающей дискретизации нескольких размеров используется для получения карты признаков прогнозирования освещенности размером $W_0 \times h_0$.

Поскольку разрешение элементов изображения, предсказанное с помощью глобального освещения, имеет проблему деформации размера, размер прогнозируемых элементов необходимо масштабировать, чтобы восстановить исходное разрешение изображения.

Операция детальной реконструкции работает следующим образом:

– Потому что предыдущие операции были основаны на операциях глобального прогнозирования освещенности. Однако размер изображения изменяется при выполнении операций повышающей и понижающей

дискретизации, что неизбежно приводит к потере некоторой подробной информации об изображении. Чтобы устранить этот недостаток, сеть разработала подробный процесс восстановления информации.

Поскольку исходное входное изображение содержит более богатую визуальную информацию, чем визуальные особенности после обработки признаков, подробную информацию об исходных визуальных признаках можно использовать в качестве дополнения к признаку, что в конечном итоге создает улучшенный эффект с большей детализацией.

Операции потери признаков между минимизированным восстановленным изображением $F(X, \Theta)$ и исходным реальным изображением Y для выполнения расчета нормы $L1$ для оптимизации. Норма $L2$ затем используется для шумоподавления улучшенного изображения. Функция потерь представлена в формуле.

ResNet , то есть глубокая остаточная сеть. Глубокая остаточная сеть, уложенная в 50-слойную сеть, представлена как ResNet50. Эта сеть была предложена в 2015 году и заняла первое место по показателям точности классификации в конкурсной задаче классификации ImageNet.

Из-за этот метод Структура проста, а эффект значителен, поэтому многие последующие методы глубокой модели построены на структуре модели нейронной сети ResNet50 или ResNet101. ResNet можно увидеть в задачах обнаружения, классификации или семантической сегментации изображений. Даже знаменитая система искусственного интеллекта Alpha Zero также использует модель нейронной сети ResNet, что полностью доказывает отличную производительность сети ResNet.




Рисунок 7 – Модель данных

С постоянным развитием глубоких нейронных сетей модели начали развиваться в сторону глубины. Однако углубление глубины сети также привело к снижению производительности. Причина в том, что огромные параметры слишком глубокой нейронной сети трудно поддаются. Подгонка приводит к переобучению. Чтобы решить эту проблему, предложили модель глубокой остаточной сети ResNe, использует операцию установки нуля остаточного сопоставления оптимально обученных узлов сети, чтобы решить проблему, заключающуюся в том, что точность снижается по мере увеличения глубины сети, оставляя только тождественное сопоставление. Эта операция может сделать модель нейронной сети всегда теоретически в оптимальное состояние, следовательно, точность модели нейронной сети не будет иметь иерархического обрыва. Схема структуры сети ResNet50 показана на рисунке модели нейронной сети Inception заключается

Операция самостоятельного выбора настроек фильтра модели реализована посредством работы модуля Inception. Этот процесс не требует вмешательства человека. После вышеуказанных операций параметры модели

нейронной сети могут быть автоматически изучены, поэтому можно добавить все функции и, наконец, подключить выходы различных фильтров для достижения в аппроксимации оптимального локального разреженного решения путем обратного распространения ошибки плотных компонентов, извлеченных из изображения.




Рисунок 8 – экран входа в систему

Операция самостоятельного выбора настроек фильтра модели реализована посредством работы модуля Inception . Этот процесс не требует вмешательства человека. После вышеуказанных операций параметры модели нейронной сети могут быть автоматически изучены, поэтому можно добавить все функции и, наконец, подключить выходы различных фильтров для достижения интеллектуального выборочного обучения нейронной сети. Критериями проектирования этой модели являются следующие три пункта: Старайтесь избегать попадания способности представления признаков модели в узкое место, то есть размер карты признаков должен медленно уменьшаться; информационный поток, очевидно, не может пройти через нее. сильно сжатые слои во время прямого распространения, то есть узкое место

выражения. Попробуйте использовать сеть вместо многомерного представления визуальных особенностей входного изображения; это облегчит обработку извлеченных многомерных функций с помощью сетевой модели, что облегчит модели распознавание высоких -размерные особенности, что ускоряет разработку модели. Пространственную агрегацию можно выполнять на низкоразмерных вложениях, не беспокоясь о потере большого количества информации.

Xception – это новая сетевая модель, предложенная Google, которая оптимизирует и улучшает InceptionV3. Эта модель реализует распределенную обработку корреляции каналов и пространственной корреляции. В этой модели используется новейший модуль Inception, заменяющий обычную сверточную нейронную сеть в InceptionV3. Процесс структурной деформации выглядит следующим образом: Освещение слиянием ближнего инфракрасного и видимого света: благодаря вспомогательному освещению с источником ближнего инфракрасного света 850 нм он может проникать сквозь кожуру фруктов и овощей для обнаружения внутренних дефектов (например, синяков на яблоках), избегая при этом проекции спеклов сухого лазера видимого света для улучшения обнаружения деформации поверхности, что подходит для 3D-реконструкции в темных условиях и алгоритмов улучшения изображений при слабом освещении.

Глубокое обучение шумоподавления использует U-Net или GAN для улучшения контрастности изображений при слабом освещении, а скорость распознавания плесени на чернике увеличивается с 60% до 90%+9. Технология многокадрового синтеза: благодаря непрерывной съемке изображений с низкой экспозицией, слиянию и шумоподавлению подходит для динамического обнаружения складских роботов. Технология обнаружения невидимого света.

Эта функция предназначена в основном для пользователей, чья категория пользователя Merchant, чтобы добавить новую информацию о продукте.

Проектирование информационной системы. Исследование алгоритма обнаружения спелых фруктов при слабом освещении, основанного на глубоком обучении" предполагает создание системы, которая будет автоматизировать процесс управления магазином, обеспечивая эффективное взаимодействие между сотрудниками, клиентами и товарными запасами.

Роль:	Промышленный клиент Малый участник Привилегированный участник	Дата открытия:	2015-12-02
Имя:	Участник А	Дата истечения срока:	2015-12-25
Почта:	313596790@qq.com	Номер телефона:	18765656565
Пароль:	Введите пароль	Удлинённый номер:	370000000000000000
Подтвердите пароль:	Подтвердите пароль	Период открытия:	2
Привилегии:	121	Состояние:	Нормальный

Технология: 313596790

Держать Отмена

Рисунок 9 – Строка меню

Эта функция предназначена в основном для пользователей, чья категория пользователя Merchant, чтобы добавить новую информацию о продукте. Проектирование информационной системы. Исследование алгоритма обнаружения спелых фруктов при слабом освещении, основанного на глубоком обучении" предполагает создание системы, которая будет автоматизировать процесс управления магазином, обеспечивая эффективное взаимодействие между сотрудниками, клиентами и товарными запасами.

2.3.1 Проектирование цепей управления

Тестирование всей модели глубокой нейронной сети полностью проводится в режиме тестирования системы. Тестирование системы – это операционная модель, которая проверяет, может ли вся программная система

работать разумно и могут ли функциональные требования программного обеспечения работать нормально.




Рисунок 10 – Товары для аудита

Теоретически Система может быть Тестирование определяется как абстрактная концепция, включая также жизненный цикл программного обеспечения. Чтобы гарантировать, что каждый жизненный цикл модели программного обеспечения находится в разумных пределах, требуется детальное тестирование программного обеспечения всей системы

Результаты испытаний могут интуитивно показать фактический эффект работы функции программного обеспечения, наличие ошибочного кодирования во всей системе, не соответствующего конструкции, а также плавность и надежность работы всей системы.

Поэтому мы разрабатываем тестовые сценарии, подходящие для этой системы, на основе собственных функций системы, прогнозируем результаты, которые даст каждый вариант использования, реализуем соответствующие варианты использования и систематически анализируем полученные результаты.

Тестирование проекта в основном преследует две цели: во-первых, проверить способность нейронной сети GLADNet улучшать изображения при слабом освещении, то есть отправить исходный набор тестовых данных при слабом освещении в нейронную сеть GLADNet для тестирования улучшения при слабом освещении. , и наблюдать эффект его усиления. Оценивать на основе эффективности.

Второй – проверить способность обнаружения классификации изображений в сквозной интегрированной модели, то есть улучшенные функции исходного изображения при слабом освещении отправляются в ResNet50 , InceptionV3 и Xception для обучения функциям классификации соответственно, а также измерения размеров. представляют собой функции изображения, выполняют объединение функций и отправляют их на полносвязный слой для тестирования. Тестирование «белого ящика» и «черного ящика» наиболее часто используемые методы. Вообще говоря, тестирование черного ящика – это метод, который люди привыкли

использовать для тестирования и который применяется при разработке систем различного масштаба.

– Основное различие между ними заключается в направлении тестирования: первое проверяет сегменты программы, находит проблемы в коде, модифицирует и улучшает код для достижения полных функций системы. Тестирование черного ящика заключается в тестировании в функциональном направлении после внедрения системы. Посредством конкретной работы каждой функции выясняется, какие функции системы нельзя использовать нормально, а затем проверяется код, чтобы максимизировать функции всей системы. система. хорошо.

Я предпочитаю тестирование методом черного ящика. Этот метод тестирования позволяет избежать сложных операций с кодом, сэкономить много времени и облегчить поиск проблемы. Более целенаправленные проблемы являются характеристиками тестирования черного ящика, поэтому этот метод больше подходит для людей. использовать.

– Объем испытаний включает в себя тестирование улучшения качества при слабом освещении на исходном наборе тестовых данных при слабом освещении и тестирование классификации на улучшенных изображениях.

Тест улучшения при слабом освещении: отправьте исходный набор тестовых данных при слабом освещении в нейронную сеть GLADNet для тестирования улучшения при слабом освещении.

Классификационный тест улучшенного изображения: набор функций расширенного изображения отправляется в сеть миграции для обучения функций, генерируются три набора функций для объединения функций и, наконец, отправляются на полносвязный уровень для реализации обучения модели классификации.

Исходный набор тестовых данных при слабом освещении отправляется в нейронную сеть GLADNet для тестирования улучшения при слабом освещении. Таблица тестовых примеров улучшения при слабом освещении показана в Таблице 2.

Таблица 2-1. Тестовые примеры улучшения при низкой освещенности

Имя	Можно ли успешно выполнить улучшение при слабом			
Реализовать	Улучшение изображения при слабом освещении			
Тестировани	Успешное улучшение при слабом освещении			
Номер варианта	Тестовы й контент	прецедент	ожидае мый	Результаты теста
1	2	3	4	5
1	Загрузите тестовый набор данных в генератор набора данных изображений.	Оригинальн ый набор файлов изображений при слабом освещении	Создание предварител ьно обработанны х изображени й (например, переворот, изменение насыщеннос ти и т. д.)	Успешно создано
2	Отправьте обработанные данные в нейросеть GLADNet для обучения.	Сгенерирова нный пакет набора данных	Успешно е обучение итерации	обучение для достижения успеха
3	Вывод улучшенного изображения при	Пакет данных тестового набора	Улучшен ное изображение успешно создано.	Успешное улучшение
4	Интегриру йте расширенные функции изображений в сеть миграции ResNet для обучения функциям.	Расширенны й набор данных изображений	Сгенерир уйте векторы признаков с размерами (1 , 1 , 2048)	обучение для достижения успеха
5	Отправьте расширенный набор функций изображения в сеть миграции	Расширенный набор данных изображений	Сгенерируйт е векторы признаков с размерами (1 , 1 , 2048)	обучение для достижения успеха

	InceptionV3 для обучения функциям.			
--	--	--	--	--

Продолжение таблицы 2

1	2	3	4	5
6	Расширенн ый набор функций изображения отправляется в сеть передачи Хсептiон для обучения функциям.	Расширенны й набор данных изображений	Сгенерир уйте векторы признаков с размерами (1 , 1 , 2048)	обучение для достижения успеха
7	Выполните интеграцию модели по извлеченным функциям трех моделей.	3 набора векторов признаков с размерами (1 , 1 , 2048)	Создайте вектор признаков размером 2048*3.	успех
8	Отправьте его на полносвязный уровень для тестирования	признаков размером 2048*3	Классифи кация успешна	Классификация успешна

3 АЛГОРИТМ ОБНАРУЖЕНИЯ ОВОЩЕЙ И ФРУКТОВ

3.1 Стадия разработки тестирования фруктов и овощей

3.1.1 Разработка алгоритма обнаружения

Модель этого проекта представляет собой сквозную модель нейронной сети, как показано на рисунке 11 модель использует модель нейронной сети GLADNet для выполнения улучшения и извлечения признаков на исходных данных изображения при слабом освещении. Затем три различные модели нейронной сети ResNet50, Inceptionv3 и Xception частично переносятся с помощью технологии трансферного обучения для обучения улучшенных признаков изображения по отдельности для создания трех наборов признаков с размерами.

Затем три набора признаков объединяются, и объединенные признаки отправляются в полностью подключенную нейронную сеть для обучения для обнаружения зрелости изображений фруктов в условиях слабого освещения, чтобы определить, созрел ли фрукт и нужно ли его собирать. Сквозная модель нейронной сети позволяет модели максимально перейти от исходных входных данных к конечным выходным данным, предоставляя модели больше возможностей для автоматической настройки в соответствии с данными, что повышает общую пригодность модели и может значительно упростить использование модели и повысить ее простоту.

Алгоритмический поток этого проекта в основном делится на три этапа: улучшение при слабом освещении, глубокое визуальное извлечение признаков на основе трансферного обучения и распознавание классификации. Алгоритмический поток показан на рисунке Улучшение при слабом освещении:

На этом этапе модель нейронной сети улучшения изображений при слабом освещении GLADNet используется для улучшения освещенности и реконструкции деталей входных данных исходного изображения при слабом освещении. Принцип делится на два этапа: первый этап заключается в

построении сети визуального кодека для выполнения глобального прогнозирования освещенности на исходном изображении при слабом освещении, которое подверглось операциям по понижению дискретизации, чтобы получить глобальное представление визуальных признаков. Вторым шагом является создание реконструктора деталей на основе сверточной нейронной сети для восстановления деталей, потерянных при масштабировании изображения.

Глубокое извлечение визуальных признаков на основе трансферного обучения: для повышения точности классификации и распознавания спелых фруктов в данной статье используется идея разработки алгоритма трансферного обучения для переноса трех моделей нейронных сетей классификации изображений ResNet50, Inceptionv3 и Xception, которые были предварительно обучены с использованием больших объемов данных, на конкретные задачи. Метод машинного обучения ансамблевого обучения используется для объединения визуальных признаков, извлеченных различными классификационными сетями.

Классификация и распознавание: на основе двухэтапных задач, описанных выше, разработан сетевой модуль расчета вероятности классификации путем объединения однослойного полностью связанного слоя и алгоритма расчета вероятности классификации softmax для обучения и расчета вероятности категории признаков, извлеченных и интегрированных различными моделями сетей классификации. Это делается для определения степени зрелости фруктов на снимках при слабом освещении, чтобы определить, созрел ли фрукт и нужно ли его собирать.

Сквозная модель нейронной сети позволяет модели максимально перейти от исходных входных данных к конечным выходным данным, предоставляя модели больше возможностей для автоматической настройки в соответствии с данными, что повышает общую пригодность модели и может значительно упростить использование модели и повысить ее простоту.

Алгоритмический поток этого проекта в основном делится на три этапа: обработка входного изображения при слабом освещении для получения изображения при нормальном освещении, миграция задач предварительно обученных моделей ResNet50, Inceptionv3 и Xception через алгоритм трансферного обучения для извлечения визуальных признаков глубокого уровня и, наконец, классификация и распознавание извлеченных признаков.




Рисунок 11 – Диаграмма прецедентов

Тестирование всей модели глубокой нейронной сети выполняется полностью в режиме тестирования системы. Тестирование системы — это операционная модель, которая проверяет, может ли вся система программного обеспечения работать разумно и могут ли функциональные требования программного обеспечения работать нормально.

Теоретически тестирование системы можно определить как абстрактное понятие, и жизненный цикл программного обеспечения также включается. Чтобы гарантировать, что каждый жизненный цикл модели программного обеспечения находится в разумных пределах, требуется детальное тестирование программного обеспечения всей системы.

Результаты тестирования наглядно демонстрируют фактический эффект работы функций программного обеспечения, наличие ошибочных кодов во всей системе, не соответствующих проекту, а также плавность и надежность работы всей системы.

Поэтому тестовые случаи, подходящие для данной системы, разрабатываются на основе собственных функций системы, результаты

каждого случая прогнозируются, соответствующие случаи реализуются, а полученные результаты систематически анализируются.

Тестирование проекта преследует две основные цели: одна из них — проверить способность нейронной сети GLADNet улучшать изображения, полученные при слабом освещении, то есть отправить исходный набор тестовых данных для слабой освещенности в нейронную сеть GLADNet для тестирования улучшения изображений при слабом освещении, а также наблюдать эффект улучшения и оценивать его на основе этого эффекта.

Вторая задача — протестировать возможности обнаружения классификации изображений сквозной интегрированной модели, то есть отправить улучшенные исходные характеристики изображения при слабом освещении в ResNet50, InceptionV3 и Xception для обучения характеристик классификации, сгенерировать характеристики изображения с размерами , выполнить слияние характеристик и отправить их в полностью связанный слой для тестирования. Наиболее часто используются методы тестирования «белого ящика» и «черного ящика».

В общем, тестирование черного ящика — это метод тестирования, который люди привыкли использовать при разработке систем разных масштабов. Вот краткое введение в разницу между ними: Основное различие между ними заключается в направлении теста. Первый проверяет сегменты программы, находит проблемы в коде, изменяет и улучшает код, и таким образом достигает идеальной реализации функций системы. Тестирование черного ящика проводится после внедрения системы.

Оно тестирует систему в функциональном направлении. Выполняя определенные операции над каждой функцией, обнаруживается, какие функции системы не могут использоваться в обычном режиме. Затем код проверяется для оптимизации функциональности всей системы.

Я предпочитаю тестирование черного ящика, которое позволяет избежать сложных операций кода, сэкономить много времени и облегчить поиск проблем. Тестирование черного ящика характеризуется более четким

определением проблем, поэтому этот метод используется большим количеством людей.

Тестирование включает в себя тест улучшения изображений при слабом освещении на исходном тестовом наборе данных для слабом освещении и тест классификации на улучшенных изображениях. Тест улучшения качества изображения при слабом освещении: Исходный набор данных теста при слабом освещении подается в нейронную сеть GLADNet для тестирования улучшения качества изображения при слабом освещении.

Выполнить тест классификации на улучшенном изображении: отправить набор признаков сгенерировать три набора признаков для слияния признаков и, наконец, отправить их в полностью связанный слой для обучения модели классификации.




Рисунок 12– Диаграмма прецедентов

Среди них $I_b(X)$ - улучшенное изображение. На данный момент контраст освещения изображения является подходящим, а распределение интенсивности освещения также очень равномерным. $I_d(X)$ Это исходное изображение с низкой освещенностью, которое не было отсортировано алгоритмом улучшения. X – это визуальный признак, извлеченный сверточной нейронной сетью в образце изображения. Блок или конкретный пиксель $F(\cdot)$ – это оператор отображения освещения, который определяется как функция, основанная на источнике света, и l представляет собой расстояние относительного положения между объектом в визуальном изображении. образец и соответствующий источник света. В описанном выше процессе входное исходное изображение при слабом освещении $I_d(X)$ улучшается с помощью гауссова процесса для получения улучшенного изображения $I_b(X)$.

Этот метод дополнительно повышает производительность модели улучшения изображения при слабом Классификация изображений обычно относится к серии операций с объектами, выполняемых компьютером над исходным изображением для окончательного получения векторного представления, богатого характеристиками категорий. Эта задача является чрезвычайно важной задачей фундаментального исследования в задачах компьютерного зрения. Такие задачи обычно включают в себя два процесса: извлечение признаков и классификацию признаков.

Традиционные методы извлечения признаков часто используют традиционные алгоритмы машинного обучения или функции, связанные с обработкой изображений, освещении и а затем классифицируют извлеченные визуальные признаки с помощью статистических методов. Этот метод приводит к неспособности эффективно использовать потенциальную корреляцию между данными и невозможности получения эффективных глубоких визуальных функций.

Благодаря большому успеху глубоких нейронных сетей в компьютерной области также широко предлагались алгоритмы

классификации изображений на основе глубоких нейронных сетей. Предоставляет ценный повышает общую пригодность модели. упрощение использования модели и повышение ее простоты использования.

Алгоритм этого проекта в основном разделен на три этапа Улучшение при слабом освещении: на этом этапе используется модель нейронной сети улучшения изображения при слабом справочный опыт для последующих

```
fi
# Look for pre-existing ROCm v6 before downloading the dependencies
for search in "${HIP_PATH:-''}" "${ROCM_PATH:-''}" "/opt/rocm" "/usr/lib64"; do
    if [ -n "${search}" ] && [ -e "${search}/libhipblas.so.2" -o -e "${search}/lib/libhipblas.so.2" ]; then
        status "Compatible AMD GPU ROCm library detected at ${search}"
        install_success
        exit 0
    fi
done

status "Downloading AMD GPU dependencies..."
$SUDO rm -rf /usr/share/ollama/lib
$SUDO chmod o+x /usr/share/ollama
$SUDO install -o ollama -g ollama -m 755 -d /usr/share/ollama/lib/rocm
curl --fail --show-error --location --progress-bar "https://ollama.com/download/ollama-linux-amd64-rocm.tgz${VEF"
| $SUDO tar zx --owner ollama --group ollama -C /usr/share/ollama/lib/rocm .
install_success
status "AMD GPU ready."
exit 0
```

Рисунок 13 – Модель кривой колебания

Эта задача является чрезвычайно важной задачей фундаментального исследования в задачах компьютерного зрения. Такие задачи обычно включают в себя два процесса: извлечение признаков и классификацию признаков.

Традиционные методы извлечения признаков часто используют традиционные алгоритмы машинного обучения или функции, связанные с обработкой изображений, для выполнения проектирования признаков изображений, а затем классифицируют извлеченные визуальные признаки с помощью статистических методов. Этот метод приводит к неспособности эффективно использовать потенциальную корреляцию между данными и невозможности получения эффективных глубоких визуальных функций.

Благодаря большому успеху глубоких нейронных сетей в компьютерной области также широко предлагались алгоритмы классификации изображений на основе глубоких нейронных сетей.

Среди них алгоритмы классификации изображений на основе сверточных нейронных сетей достигли оптимальной производительности в задачах классификации изображений. Многоуровневые сверточные нейронные сети извлекают глубокие визуальные особенности, а возможности сверточных нейронных сетей по захвату пространственной информации еще больше улучшают возможности распознавания изображений.

Для извлеченных визуальных функций необходимо разработать классификатор для эффективной классификации изображения. Этот процесс часто включает в себя разработку эффективного алгоритма классификации для классификации и обучения классификатора изображений для дальнейшего повышения точности классификации модели. Ранние классификаторы изображений часто использовали алгоритм обратного распространения ошибки ^[10] для обучения одноуровневых нейронных сетей.

Поскольку скрытый слой имеет только один слой, модель может легко соответствовать локальному оптимуму, что приводит к переобучению модели. Благодаря постоянному развитию компьютерного оборудования и вычислительной мощности, реализация моделей глубоких нейронных сетей стала возможной. Его многоуровневые скрытые слои могут предоставить модели более богатую потенциальную информацию.

Многоуровневые сетевые настройки помогают этого проекта представляет собой модель нейронной сети сквозного режима, как показано на рисунке 14. Эта модель использует модель нейронной сети GLADNet для улучшения и извлечения признаков из исходных данных изображения при слабом освещении. а затем с помощью технологии обучения миграции частично переносятся три разные модели нейронных сетей: ResNet50 , I inceptionv3 и Xception , чтобы обучить , чтобы обучить расширенные функции изображения соответственно, чтобы сгенерировать три набора наборов

функций с размерностями и объединить эти три набора. Выполните объединение признаков и отправьте расширенные функции изображения соответственно модели изучать более

ResNet50, Inceptionv3 и Xception, чтобы обучить расширенные функции изображения соответственно, чтобы сгенерировать три набора наборов функций с размерностями и объединить эти три набора. Выполните объединение признаков и отправьте объединенные признаки в полностью подключенную нейронную сеть для обучения обнаружению зрелости изображений фруктов при низкой освещенности, чтобы определить, созрел ли плод и нужно ли его собирать.



Рисунок 14 – Модель обнаружения

Модель нейронной сети сквозного режима позволяет модели максимально перемещаться от исходных входных данных к конечному выводу, предоставляя модели больше места для автоматической настройки в соответствии с данными, что значительно повышает общую пригодность модели. упрощение использования модели и повышение ее простоты использования. Алгоритм этого проекта в основном разделен на три этапа

Улучшение при слабом освещении: на этом этапе используется модель нейронной сети улучшения изображения при слабом освещении GLADNet для улучшения освещенности изображения и детальной реконструкции на

входных исходных данных изображения при слабом освещении. Принцип разделен на два этапа: первый шаг - построить сеть визуального кодирования и декодирования.

Исходное изображение при слабом освещении, которое было подвергнуто субдискретизации, используется для прогнозирования глобального освещения для получения глобального представления визуальных функций. Второй шаг – построить реконструктор деталей на основе сверточной нейронной сети для восстановления деталей, потерянных при масштабировании изображения.

3.2 Тестирование программного обеспечения

3.2.1 Аппаратная модель обнаружения фруктов и овощей

Вес ребра отражает сходство изменений значений информационной энтропии двух вершин, соединенных с ребром; чем больше вес, тем более схожи изменения. По количеству вершин подграфы G_t (V_t , E_t) можно разделить на четыре категории: 2-вершинные подграфы, 3-вершинные подграфы, 4-вершинные подграфы и 5-вершинные подграфы. В усовершенствованном сверточном нейронном алгоритме, представленном в данной статье, значение подграфа заключается в представлении сходства изменений энтропии между всеми вершинами, содержащимися в нем. Поэтому для данного исследования имеет значение только полный подграф.

В предлагаемом усовершенствованном алгоритме сверточного нейронного обнаружения переопределен метод расчета поддержки подграфа. Поддержка подграфа определяется как представляет собой среднее значение скорости изменения значения информационной энтропии каждой вершины в подграфе g_j , отражающее амплитуду изменения каждого значения информационной энтропии; $S(g_j)$ – среднее значение веса каждого ребра в подграфе g_j , отражающее сходство изменений каждой информационной энтропии. При нормальной работе видеотерминала Интернета вещей с высокой мощностью энтропия информации пяти типов атрибутов трафика

видеотерминала Интернета вещей относительно стабильна, и посредством майнинга можно получить меньше частых подграфов.

В этих ограниченных среди часто встречающихся подграфов наиболее распространены подграфы с двумя вершинами, за ними следуют подграфы с тремя вершинами, а подграфы с четырьмя и пятью вершинами практически не встречаются. Однако при аномальном трафике видеотерминала количество часто появляющихся фрагментов изображения значительно увеличивается. Среди них наиболее очевидны изменения в количестве 3-, 4- и 5-вершинных подграфов. Это связано с тем, что при возникновении ненормальной ситуации значения энтропии нескольких атрибутов часто значительно увеличиваются или уменьшаются одновременно, а поддержка подграфа, определяемая формулой, отражает сходство больших амплитудных изменений значений энтропии каждой вершины в одно и то же время.

В связи с этим для четырех типов подграфов устанавливается четырехмерный вектор аномалий, который используется для представления доли частых подграфов в различных типах подграфов. Затем изменение аномального вектора используется для определения того, является ли трафик аномальным. Тогда аномальный вектор $G_t(V_t, E_t)$ в момент времени t выражается как.

Где a , a , a и a – двойные пары, которые часто встречаются в графе G_t . Соотношение вершин, 3-вершинных, 4-вершинных и 5-вершинных подграфов, то есть количество таких подграфов, деленное на общее количество подграфов. В то же время вектор аномалии $\{a_1, a_2, \dots, a_t\}$ в момент времени t до момента времени $t+1$ может быть получен из исторических данных. Экспериментальные результаты и анализ Экспериментальной средой данной статьи является операционная система Windows, а конфигурация компьютера, используемая в эксперименте, – 16 ГБ памяти и 1 ТБ жесткого диска. Изучая значение $F1$, мы можем дополнительно изучить и улучшить производительность обнаружения сверточного нейронного алгоритма.

Чем ближе значение $F1$ к 1, тем лучше эффект обнаружения, что может соответствовать требованиям классификации и идентификации обнаружения аномального трафика. Распределение погрешности значения измерения $F1$ показано на рисунке Пакет данных видеотерминала Рисунок 1. Распределение погрешности измерения $F1$ Рис. 1 Распределение погрешности измерения $F1$ Как показано на рисунке 1, когда размер пакета данных мощного видеотерминала Интернета вещей невелик, улучшенный сверточный нейронный алгоритм оказывает большее влияние на точность обнаружения аномальных потоков данных, а значение $F1$ далеко от 1 и распределено неравномерно. По мере постепенного увеличения размера конечного пакета данных значение $F1$ приближается к 1, и можно заметить, что значение $F1$ распределено относительно равномерно. Размер пакета данных внезапно увеличился.

Проверив исходный набор данных, было обнаружено, что видеотерминал был ненормальным несколько дней около точки внезапного увеличения, что вызвало внезапное увеличение значения $F1$. На рисунке показана матрица ошибок сверточного нейронного алгоритма и усовершенствованный сверточный нейронный алгоритм, предложенный в данной статье. Среди них ось Y представляет собой истинную метку, а ось X – прогнозируемую метку.

Как показано на рисунке 15, в улучшенном сверточном нейронном алгоритме 97% обычного трафика классифицируется правильно, что лучше, чем у сверточного нейронного алгоритма. В свертке Согласно алгоритму, весь аномальный трафик данных классифицируется неправильно, включая 86% были спрогнозированы как обычный трафик данных, а как трафик вторжения. Существует В усовершенствованном сверточном нейронном алгоритме трафика видеотерминала было правильно классифицировано. Из этих категорий прогнозируются как нормальный трафик данных, а как трафик вторжений. А количество аномального трафика невелико, в сверточном нейронном алгоритме и улучшенном объеме.


```

status 'Installing NVIDIA repository...'
if curl -I --silent --fail --location "https://developer.download.nvidia.com/compute/cuda/repos/$1$2/$(uname -m)" > /dev/null; then
    curl -fsSL -o $TEMP_DIR/cuda-keyring.deb https://developer.download.nvidia.com/compute/cuda/repos/$1$2/$(uname -m)/cuda-keyring.deb
else
    error $CUDA_REPO_ERR_MSG
fi

case $1 in
    debian)
        status 'Enabling contrib sources...'
        $SUDO sed 's/main/contrib/' < /etc/apt/sources.list | $SUDO tee /etc/apt/sources.list.d/contrib.list > /dev/null
        if [ -f "/etc/apt/sources.list.d/debian.sources" ]; then
            $SUDO sed 's/main/contrib/' < /etc/apt/sources.list.d/debian.sources | $SUDO tee /etc/apt/sources.list.d/debian.sources > /dev/null
        fi
        ;;
    *)
        ;;
esac

status 'Installing CUDA driver...'
$SUDO dpkg -i $TEMP_DIR/cuda-keyring.deb
$SUDO apt-get update

```

Рисунок 15 – Внутренний привод нейронной сети

Все они были неправильно классифицированы алгоритме нейронной сети. Кроме того, в сверточных нейронных сетях. При использовании этого метода аномального трафика были правильно классифицированы, а аномального трафика были классифицированы правильно.

В усовершенствованном сверточном нейронном алгоритме аномального потока количества классифицированы правильно. С точки зрения обнаружения нормального трафика в приведенных выше данных, производительность улучшенной модели сверточного нейронного алгоритма выше, чем у сверточного нейронного алгоритма. Отлично подходит для обнаружения нештатного трафика. Из-за ненормального трафика Количество выборок относительно невелико, особенно аномальный трафик, составляющий всю выборку трафика. Традиционный сверточный нейронный алгоритм легко кластеризуется в наибольшее количество нормального трафика, что приводит к ошибкам при обнаружении аномального трафика. Подводя итог, можно сказать, что производительность улучшенного сверточного нейронного алгоритма выше, чем у традиционного сверточного нейронного алгоритма. Модель обнаружения аномального трафика видеотерминала, основанная на усовершенствованном сверточном нейронном алгоритме, сравнивается с моделью сверточного нейронного алгоритма, а

также дополнительно изучаются такие характеристики, как точность, частота ложных срабатываний (FPR) и частота потери пакетов (RTP). Точность показывает способность модели обнаружения правильно классифицировать нормальный и ненормальный трафик. FPR – это процент неправильно оцененного ненормального трафика по отношению к общему нормальному трафику. RTP представляет собой файл, отфильтрованный по модели оповещения об аномальном трафике, которая связана с нагрузкой на трафик. tsum – общее время, необходимое модели обнаружения для обработки файлов видеотерминала, tmean – среднее затраченное время, а Nd – количество файлов видеотерминала, использованных для тестирования. В таблице 1 показаны результаты обнаружения аномального трафика с помощью сверточного нейронного алгоритма и улучшенного сверточного нейронного алгоритма соответственно.

Алгоритм сверточной нейронной сети Улучшенная свертка Нейронный алгоритм как видно из таблицы 1, точность сверточного нейронного алгоритма составляет около, а точность улучшенного сверточного нейронного алгоритма составляет около. FPR улучшенного сверточного нейронного алгоритма на ниже, чем у сверточного нейронного алгоритма, в основном потому, что накопление ошибок прогнозирования в сверточном слое сверточного нейронного алгоритма приведет к снижению точности и увеличению FPR. Улучшенная сверточная нейронная сеть Среднее время, затрачиваемое методом, меньше, чем у алгоритма сверточной нейронной сети.

Таким образом, усовершенствованный сверточный нейронный алгоритм обеспечивает более высокую точность, более низкий FPR и более короткое время обнаружения. Кроме того, ввиду сложной структуры сверточного нейронного алгоритма его необходимо развернуть в центре управления видеотерминалом Интернета вещей, поэтому все пакеты данных необходимо загружать в центр управления видеотерминалом Интернета вещей для анализа. RTP сверточного нейронного алгоритма равен 0, что еще больше увеличивает нагрузку по обнаружению аномального трафика.

Напротив, усовершенствованная структура обнаружения сверточного нейронного алгоритма, предложенная в данной статье, может сократить количество пакетов данных, передаваемых в облако, на, что может снизить нагрузку по обнаружению аномального трафика. Для преодоления ограничений традиционных систем управления в условиях нелинейных факторов большое внимание привлечет метод итеративного обучения (ILC).

Основная идея ILC заключается в использовании опыта управления, накопленного в предыдущих экспериментах, для непрерывной итеративной корректировки текущего входного управляющего воздействия с целью достижения точного отслеживания желаемой траектории. Метод ILC был предложен автором ссылок. После более чем 40 лет разработки он достиг большого успеха как в теории, так и в применении. В впервые было использовано автономное итеративное управление для моделирования дорожных условий при испытании транспортных средств. Однако непрерывно изменяющиеся динамические характеристики нелинейного тестового тела приведут к снижению точности автономного итеративного управления. В теория H_∞ была добавлена к автономной итерации для проектирования контроллера обратной связи в реальном времени для формирования управления с разомкнутым и замкнутым контуром.

В работе для проведения первого моделирования и экспериментального исследования нелинейной автономной итерации использовался принцип расчета симметричного тензора нелинейного регулятора.

Для решения проблемы отсутствия основы для точности итеративного контроля и слепого определения количества итераций в была установлена основа количественной оценки путем вычисления коэффициента корреляции между ответным сигналом и ожидаемым сигналом. В работе предложен итерационный метод управления вибростолом на основе модели заменяющего образца. Этот метод обеспечивает лучший входной сигнал системы, чем традиционный итеративный метод управления, не изменяя при этом характеристики испытуемого образца. Этот метод играет важную роль в

повышении точности вибростола при воспроизведении сейсмических волн. В работе построен внешний замкнутый контур с итеративным обучающимся контроллером на основе системы ПИД-регулирования вибростола, предложены методы итеративного обучающегося управления смещением-смещением и итеративного обучающегося управления смещением-ускорением, а также проверены характеристики управления методом с помощью численного моделирования и экспериментов.

В работе предложен высокоточный метод итеративного управления в режиме реального времени (High-precision Real-time Iterative Control System, HRICS), основанный на коррекции матрицы системы, что улучшило эффективность управления системой. Однако вышеупомянутые итерационные алгоритмы в основном используют закон ПИД-регулирования и имеют фиксированные.

Если система имеет определенный коэффициент обучения, то при значительных изменениях или воздействии на нее больших внешних возмущений эффективность управления снизится или система станет нестабильной. Для решения проблемы сложности создания нелинейной модели вибростола в был принят метод испытания с синусоидальной разверткой частоты для выполнения полнодиапазонной синусоидальной развертки частоты на пустой поверхности вибростола и аппроксимации полученных данных частоты с использованием алгоритма наименьших квадратов в комплексной области для завершения идентификации передаточной функции модели вибростола. В работе используется оптимизированный чистый случайный сигнал возбуждения для повышения точности идентификации системы и, таким образом, улучшения производительности автономного итеративного управления.

В работе для определения модели таблицы сотрясений при моделировании землетрясений используется метод наименьших квадратов. Выявленная модель может хорошо воспроизводить характеристики самой системы вибростенда. Однако указанная выше идентификация все еще не

может эффективно охватить динамические характеристики системы вибрационного стола, развивающиеся с течением времени. Для решения проблемы слабого контроля традиционного вибростола в данной статье предлагается новый адаптивный итеративный алгоритм управления обучением, использующий нелинейный оптимизатор Grey Wolf. Для идентификации модели вибрационного стола используется авторегрессионная нейронная сеть с экзогенными входами (GWO-NARX).

Алгоритм адаптивного итеративного обучения создает замкнутый контур внешнего смещения на основе традиционной трехпараметрической системы управления смещением, формируя двойную замкнутую систему, тем самым лучше адаптируясь к сложности системы. Результаты показывают, что на основе GWO-NARX Адаптивный итеративный алгоритм управления обучением идентификационной модели значительно повышает точность управления вибростолом, а точность воспроизведения смещения достигает 99,8%. Данное исследование подтверждает эффективность и осуществимость предлагаемого алгоритма для повышения точности управления вибростолом и предоставляет важную справочную информацию и вдохновение для дальнейших исследований в области управления вибростолом. Нелинейная авторегрессионная нейронная сеть с экзогенными входами (NARX) — это эффективная технология прогнозирования временных рядов. Он обладает превосходными динамическими характеристиками и высокой помехоустойчивостью, что позволяет модели NARX аппроксимировать различные нелинейные системы. Сложность модели вибрационного стола тесно связана со временем, что подразумевает большой объем данных временных рядов. Нейронная сеть NARX, благодаря своей уникальной авторегрессионной структуре, может лучше учитывать характеристики системы в разные моменты времени, тем самым более эффективно фиксируя динамические характеристики системы вибростола, развивающиеся с течением времени. Таким образом, использование нейронной сети NARX для идентификации модели системы вибростола может всесторонне охватить

траекторию развития системы. Моделирование с использованием нейронной сети NARX помогает более точно описать динамические характеристики системы вибростенда, тем самым повышая точность модели. Математическое выражение нейронной сети NARX, где $y(t)$ – выход системы в момент времени t ; $f[*]$ – нелинейная функция, полученная путем подгонки нейронной сети; $x(t)$ – вход системы в момент времени t ; $d1$ и $d2$ – порядки задержки входа и выхода нейронной сети соответственно. Классическая структура нейронной сети NARX состоит из 3 слоев: входной слой имеет задержанные входные переменные длины $d1$ и задержанные выходные переменные длины $d2$; эти переменные передаются в скрытый слой, входные переменные взвешиваются, и нелинейное отображение достигается с помощью нелинейных функций активации; наконец, активированные переменные передаются в выходной слой, где выполняется взвешенное суммирование для обратной связи по результатам. Количество

где $y(t)$ – выход системы в момент времени t ; $f[*]$ – нелинейная функция, полученная путем подгонки нейронной сети; $x(t)$ – вход системы в момент времени t ; $d1$ и $d2$ – порядки задержки входа и выхода нейронной сети соответственно.

Классическая структура нейронной сети NARX состоит из 3 слоев: входной слой имеет задержанные входные переменные длины $d1$ и задержанные выходные переменные длины $d2$; эти переменные передаются в скрытый слой, входные переменные взвешиваются, и нелинейное отображение достигается с помощью нелинейных функций активации; наконец, активированные переменные передаются в выходной слой, где выполняется взвешенное суммирование для обратной связи по результатам. Количество нейронов в скрытом слое определяется по эмпирической формуле $p1$ – количество нейронов в скрытом слое; N – количество входных образцов; μ – пользовательская константа в диапазоне от 2 до 10; m – количество узлов во входном слое; n – количество узлов в выходном слое; n – оператор округления в большую сторону. В данной статье нейронная сеть NARX используется для построения электродинамической модели вибрационного

стола для имитации землетрясений. Учитывая, что в вибростолу реализовано управление смещением, входной сигнал нейронной сети NARX включает смещение и ошибку смещения между входом и выходом вибростола. Сигнал смещения, собранный поверхностью вибростола, используется в качестве выходного сигнала нейронной сети NARX. Входной сигнал смещения получается путем выполнения смешанного интегрирования по сигналу ускорения; количество нейронов в скрытом слое определяется по формуле ; наконец, для обучения сети выбирается алгоритм LM (Левенберга-Марквардта) с быстрой сходимостью и высокой точностью. Модель нейронной сети NARX на основе оптимизации Gray Wolf В 2014 году МИРДЖАЛИЛИ и др. предложили оптимизатор серого волка (GWO), вдохновленный охотничьим поведением серых волков. Алгоритм.

Целью алгоритма GWO является поиск оптимального решения в пространстве поиска заданной задачи путем моделирования поведения и социальной структуры групп серых волков.




Рисунок 16 – Поток алгоритма нейронной сети GWO-NARX

Или приближенное оптимальное решение для максимизации оптимизации конкретной целевой функции. Алгоритм GWO математически моделирует социальную иерархию волков, определяя лучшую особь как α -волка, вторую и третью лучшие особи как β -волка и ζ -волка соответственно, а оставшихся особей как ω -волка.

Алгоритм серого волка использует информацию о местоположении волка α , волка β и быстрые отборы проб и тестирование иностранной фруктовой и овощной продукции и принимать надзор со стороны сельскохозяйственного департамента. Короче говоря, нормализовать входные данные.

Или приближенное оптимальное решение для максимизации оптимизации конкретной целевой функции. Алгоритм GWO математически

моделирует социальную иерархию волков, определяя лучшую особь как α -волка, вторую и третью лучшие особи как β -волка и ζ -волка соответственно, а оставшихся особей как ω -волка. Алгоритм серого волка использует информацию о местоположении волка α , волка β и волка ζ для обновления и итерации особей волчьей стаи с целью завершения поиска оптимального решения, то есть процесса окружения добычи. Формула обновления позиции серого волка:

X – вектор положения оставшихся серых волков; k – текущий номер итерации; X_p – вектор положения добычи; D – вектор расстояния между текущим положением серого волка и добычи; A и C – параметры, как показано в формуле e – фактор сходимости, который линейно убывает от 2 до 0; r_1 и r_2 – случайные числа в диапазоне $[0,1]$. Волк α , волк β и волк ζ направляют волчью D_α , D_β , D_ζ – векторы расстояний между текущим кандидатом серым волком и оптимальными тремя волками; X_α , X_β , X_ζ – векторы положения волка α , волка β и волка ζ в текущий момент. Следующее поколение серых волков случайным образом обновляет свое положение вокруг добычи, и формула обновления такова.

В формуле: X_1 , X_2 , X_3 – векторы направления между современными волками α , β , ζ и ω ; A_1 , A_2 , A_3 – параметры волков α , β , ζ соответственно. Основная идея алгоритма нейронной сети GWO-NARX заключается в следующем: во-первых, необходимо учитывать синхронизацию входных и выходных данных в процессе моделирования нейронной сети NARX, чтобы более точно отражать динамические характеристики и историческую информацию о состоянии вибростола; во-вторых, алгоритм GWO используется для оптимизации порядка задержки ввода/вывода и количества нейронов скрытого слоя нейронной сети NARX для лучшей адаптации к динамическим характеристикам системы, тем самым улучшая способность модели к подгонке и точность прогнозирования; с помощью соответствующих функций оценки пригодности количественно определяется

структура модели, а параметры топологии модели и параметры веса сети совместно оптимизируются.

Шаги по созданию модели нейронной сети GWO-NARX следующие. Нормализовать входные данные. Задайте начальные параметры GWO и начальное значение параметра x , подлежащего оптимизации.

Инициализируйте позиции волчьей стаи и сохраните результаты в $bestX$. Определить и рассчитать функцию оценки пригодности. Запустите нейронную сеть NARX и сохраните значение функции оценки пригодности в $bestY$. Рассчитайте приспособленность каждого волка и выберите 3 лучших значения: α -волк, β -волк, ζ -волк, и обновите e , A , C и положение серого волка. Рассчитайте значение функции оценки пригодности в это время. Если оно меньше $bestY$, обновите его до нового $bestY$ и сохраните текущую позицию как $bestX$. Если функция оценки пригодности достигает требуемой точности, остановить итерацию; в противном случае обновить положение серого волка и вернуться к шагу, чтобы продолжить итерацию. Когда алгоритм прекращает итерацию, результат, сохраненный в $bestX$, является оптимальным решением, включая порядок задержки на входе, порядок задержки на выходе и количество нейронов в скрытом для обеспечения стабильности производительности начальный фактор сходимости $e = 2$ устанавливается для управления скоростью сходимости и устойчивостью алгоритма; выполняется 20 итераций для обеспечения вычислительной эффективности и эффекта оптимизации, а количество «серых волков» составляет 10 для обеспечения стабильных и эффективных результатов оптимизации при ограниченных вычислительных ресурсах; с учетом динамических характеристик и взаимосвязи входов и выходов системы начальные порядки задержки входов и выходов нейронной сети NARX устанавливаются равными 3; для обработки сложных нелинейных взаимосвязей и предотвращения переобучения количество нейронов скрытого слоя устанавливается равным 5; кроме того, минимальный градиент производительности устанавливается равным 0,000 001, и выполняется 100

тренировок для повышения способности к обобщению и эксперименте для генерации входных данных управления, которые могут создать желаемую выходную траекторию, тем самым улучшая эффективность управления. Этот метод легко адаптируется и прост в реализации. Кроме того, итеративное управление обучением не требует создания точной математической модели динамической системы. Вместо этого он генерирует оптимизированный входной сигнал посредством итерации, так что выход системы максимально близок к ожидаемому значению. Проанализируйте динамические уравнения нелинейной системы: точности прогнозирования модели. На основе вышеуказанных настроек в данной статье для идентификации модели вибростола использовались нейронные сети NARX




Рисунок 17 – Поток алгоритма нейронной сети GWO-NARX

Эксперименте для генерации входных данных управления, которые могут создать желаемую выходную траекторию, тем самым улучшая эффективность управления.


Этот метод легко адаптируется и прост в реализации. Кроме того, итеративное управление обучением не требует создания точной математической модели динамической системы. Вместо этого он генерирует

оптимизированный входной сигнал посредством итерации, так что выход системы максимально близок к ожидаемому значению.


Проанализируйте динамические уравнения нелинейной системы. В данной работе для моделирования вибростенда используется сейсмическая волна Elcentro мощностью 110 галлонов. Был проведен реальный имитационный эксперимент, и набор данных был нормализован, чтобы уменьшить сложность данных и ускорение решения градиентного спуска.

Нормализованная Формула такова: Где: u_i и Y_i – выборки данных до и после нормализации; $u_{\min}$ и $u_{\max}$ – минимальное и максимальное значения выборок соответственно. После обработки данных нейронная сеть NARX была использована для анализа модели вибростенда. Введите для идентификации.

При проведении имитационных испытаний на платформе MATLAB, для обеспечения работоспособности системы Для обеспечения стабильности производительности начальный фактор сходимости $\epsilon = 2$ устанавливается для управления скоростью сходимости и устойчивостью алгоритма; выполняется 20 итераций для обеспечения вычислительной эффективности и эффекта оптимизации, а количество «серых волков» составляет 10 для обеспечения стабильных и эффективных результатов оптимизации при ограниченных вычислительных ресурсах; с учетом динамических характеристик и взаимосвязи входов и выходов системы начальные порядки задержки входов и выходов нейронной сети NARX устанавливаются равными 3; для обработки сложных нелинейных взаимосвязей.



а) Сравнение результатов идентификации



б) Сравнение ошибок идентификации

Рисунок 18 – Модель вибростола

Предотвращения переобучения количество нейронов скрытого слоя устанавливается равным 5; кроме того, минимальный градиент производительности устанавливается равным 0,000 001, и выполняется 100 тренировок для повышения способности к обобщению и точности прогнозирования модели.

На основе вышеуказанных настроек в данной статье для идентификации модели вибростолы использовались нейронные сети NARX, CV-NARX и GWO-NARX. Результаты предыдущего контроля многократно применяются в эксперименте для генерации входных данных управления, которые могут создать желаемую выходную траекторию, тем самым улучшая эффективность управления.

Этот метод легко адаптируется и прост в реализации. Кроме того, итеративное управление обучением не требует создания точной математической модели динамической системы. Вместо этого он генерирует оптимизированный входной сигнал посредством итерации, так что выход системы максимально близок к ожидаемому значению. Проанализируйте динамические уравнения нелинейной системы:

В формуле: $x_k(t)$ – состояние системы; $y_k(t)$ – выход системы; $u_k(t)$ – управляющий сигнал системы; k – число итераций; f и g – векторные функции соответствующих размерностей соответственно. Если имеется ожидаемый выход $u_d(t)$, то цель итеративного управления обучением заключается в следующем: при заданном начальном состоянии $x(0)$ и ожидаемом выходе $y_d(t)$ во временной области $t \in [0, T]$ в соответствии с определенной скоростью обучения, делая $u_k(t) \rightarrow u_d(t)$, так что $y_k(t) \rightarrow y_d(t)$.

Экспериментальные результаты показывают, что при той же модели идентификации метод AILC имеет значительные преимущества в повышении точности воспроизведения формы сигнала при испытаниях на вибростенде. Диапазон его выходной ошибки уже, а максимальная ошибка уменьшается более существенно.




Рисунок 19 – Визуальная модель фруктов и овощей

В настоящее время развитие технологий быстрого обнаружения идет относительно быстрыми темпами. Однако, учитывая ограниченное улучшение возможностей обнаружения (чувствительности) новых приборов, выпускаемых в Китае, существуют два направления развития оборудования: одно из них – увеличение количества каналов до шестнадцати, двадцати четырех или даже выше.

Хотя число каналов обнаружения приборов значительно возросло, предварительная обработка по-прежнему должна быть выполнена самим персоналом обнаружения. Увеличение числа портов каналов обнаружения фактически не увеличивает эффективность быстрого обнаружения. Если прибор быстрого обнаружения сможет объединить все или часть этапов предварительной обработки в прибор быстрого обнаружения, уменьшив зависимость от ручного управления персоналом, проводящим обнаружение, на этих этапах, увеличение количества каналов значительно повысит эффективность работы по обнаружению, а также станет крупным технологическим прорывом. Другим направлением является интеграция компьютера, принтера, модуля Wi-Fi и прибора быстрого обнаружения в единую машину, что сокращает количество приборов быстрого обнаружения и компьютерных систем.

Он решает проблему совместимости драйвера последовательного порта традиционного программного обеспечения, уменьшает занимаемое

пространство в комнате и преодолевает ограничение локального физического сетевого порта на приборе быстрого обнаружения. Это хорошая попытка. Для ускорения исследований по технологии предварительной обработки лука, чеснока, кориандра, лука-порей и других продуктов для быстрого обнаружения необходимо попробовать использовать адсорбент в методе QuEChERS для очистки раствора образца после предварительной обработки.

С другой стороны, необходимо как можно скорее добавить стандарт быстрого обнаружения остатков пестицидов в фруктовых продуктах в национальный стандарт. Особенно для фруктовых продуктов, богатых пигментами, еще предстоит подтвердить, можно ли использовать метод скорости ингибирования фермента для быстрого обнаружения остатков пестицидов. Поощрять сельскохозяйственных операторов строить, эксплуатировать и содержать пункты тестирования Департамент сельского хозяйства должен поощрять сельскохозяйственных операторов активно строить, эксплуатировать и содержать пункты тестирования. Демонстрационные кооперативы, ведущие сельскохозяйственные предприятия,

Когда семейные фермы и другие хозяйствующие субъекты, а также производственные базы «трех продуктов и одного стандарта» подают заявки на сельскохозяйственные проекты, соответствующие департаменты должны рассмотреть возможность добавления показателей приемки или оценки для строительства, надзора и обслуживания лабораторий для проведения низовых испытаний, а также ускорить создание системы быстрой проверки возможностей проведения испытаний для лабораторий для проведения низовых испытаний. В то же время, чтобы предотвратить и контролировать риски, связанные с импортом фруктов и овощей, мы должны обеспечить связь между подтверждением происхождения и доступом на рынок.

Местные сельскохозяйственные операторы отвечают за распространение импортной фруктовой и овощной продукции, которая также подвержена потенциальным рискам загрязнения во время производства,

хранения и транспортировки. Учитывая специфику свежей сельскохозяйственной продукции, необходимо проводить быстрые отборы проб и тестирование иностранной фруктовой и овощной продукции и принимать надзор со стороны сельскохозяйственного департамента. Короче говоря, создание, эксплуатация и развитие низовой системы быстрого обнаружения остатков пестицидов в овощеводстве и фруктах не могут быть отделены от заботы и поддержки правительств всех уровней, а также от удовлетворения и поддержки местного населения.

Низовым лабораториям по испытанию качества и безопасности сельскохозяйственной продукции необходимо начать с собственного опыта, усердно работать и заложить прочную основу для строительства города с гарантированным качеством и безопасностью сельскохозяйственной продукции.

ЗАКЛЮЧЕНИЕ

Проверка качества фруктов и овощей является ключевым звеном в сельскохозяйственном производстве, послеуборочной обработке и переработке пищевых продуктов и напрямую связана с рыночной стоимостью продукта и удовлетворенностью потребителей. С развитием науки и техники технология испытаний овощей и фруктов прошла путь от традиционной ручного опыта и разрушающего физико-химического анализа до различных эффективных и точных методов неразрушающего контроля. В данной статье систематически рассматриваются современные основные технологии обнаружения овощей и фруктов, включая методы, основанные на электрических свойствах, акустических свойствах, электронном носе, машинном зрении, спектральном анализе и глубоком обучении. В нем анализируются принципы, статус применения, преимущества и недостатки каждой технологии, а также рассматриваются будущие тенденции развития с целью предоставить справочную информацию для исследований и применения в смежных областях.

Традиционные методы испытаний и развитие технологий неразрушающего контроля Традиционные методы проверки зрелости и качества плодов в основном опираются на опыт фермеров, выращивающих фрукты, или на сложные физико-химические эксперименты с использованием аналитических приборов. Метод эмпирического суждения в значительной степени подвержен влиянию субъективных факторов, имеет низкую эффективность и высокий уровень ошибочных суждений; в то время как физико-химический экспериментальный метод обычно требует разрушения плодовой ткани, что является громоздким и неэффективным, что затрудняет проведение крупномасштабных испытаний.

Эти традиционные методы постепенно продемонстрировали свои ограничения в современных системах сельскохозяйственного производства и переработки продуктов питания.

Развитие технологий неразрушающего контроля направлено именно на устранение недостатков традиционных методов. Технология неразрушающего плодозвуковой вибрации, показала хорошие результаты как в калибровочном наборе, так и в наборе прогнозирования. Результаты проверки при комнатной температуре и 8°C могут хорошо отражать твердость киви. Это свидетельствует о том, что акустическая технология обладает определенной устойчивостью в различных условиях окружающей среды, что обеспечивает возможность ее практического применения. Технология обнаружения на основе химических характеристик и машинного зрения.

Благодаря развитию сенсорных технологий и алгоритмов обработки изображений технология обнаружения, основанная на химических характеристиках и характеристиках внешнего вида фруктов, достигла значительного прогресса. Эти технологии позволяют улавливать едва заметные изменения, которые трудно обнаружить человеческим органам чувств, обеспечивая более объективный и точный метод оценки качества фруктов. Электронный нос и технология анализа запахов Технология электронного носа имитирует обонятельную систему человека и использует матрицу газовых датчиков и алгоритм распознавания образов для обнаружения летучих органических соединений (ЛОС), выделяемых в процессе созревания фруктов.

Фрукты разной степени зрелости производят уникальные ароматические отпечатки, такие как определенные фенолы, эфиры и этилен³. Типичная система электронного носа состоит из устройства отбора проб, матрицы датчиков, блока предварительной обработки сигнала и алгоритма распознавания образов³. Исследования показали, что электронные носы хорошо справляются с определением спелости различных фруктов. При анализе киви с использованием системы электронного носа PEN³ точность распознавания модели на основе линейного дискриминантного анализа (ЛДА)

достигала 100%³. Система электронного носа с 16 датчиками, разработанная для древовидных томатов, достигла точности классификации для трех стадий зрелости³. Модель распознавания, созданная путем объединения бионических обонятельных данных личи с методами анализа главных компонент (PCA) и LDA, также достигла точности . Электронный нос также показал хорошие результаты при обнаружении персиков и яблок, при площади.

Анализ цвета является важным применением машинного зрения. Бласко и др. использовали метод усреднения пикселей RGB и порогового значения R/G для различения четырех сортов граната с вероятностью успеха более . Юань Цзиньли преобразовал значения RGB в режим HIS при обнаружении цвета яблока, извлек 7 доменов цветности гистограммы цветности в качестве признаков и применил алгоритм роя частиц для оптимизации нейронной сети для классификации¹⁰. Лу Вэйци и др. извлекли общее среднее значение компонентов R, G и B изображения винограда и добились высокоточного распознавания сорта (среднеквадратичная ошибка всего 0,000252%) посредством преобразования признаков.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1 Абрамов, С. К. Гиперспектральный анализ сельхозпродукции: методы и алгоритмы [Электронный ресурс] / С. К. Абрамов. – Красноярск : СибГУ, 2023. – 114 с. – Elibrary. – Режим доступа: <https://elibrary.ru/item.asp?id=54321-987> – 18.12.2025.

2 Амурский государственный университет. Открытый информационный ресурс по агропродовольственным технологиям [Электронный ресурс]. – Благовещенск, 2024. – Режим доступа: <https://www.amursu.ru/> – 16.12.2025.

3 Белов, Г. В. Нейросетевые технологии сортировки плодоовощной продукции [Учебное пособие] / Г. В. Белов. – Москва : АгроНаука, 2022. – 176 с.

4 Васильев, А. И.; Соколова, Е. В. Современные методы анализа качества сельскохозяйственной продукции [Электронный ресурс] : учебное пособие / А. И. Васильев, Е. В. Соколова. – Москва : РГАУ-МСХА, 2021. – 89 с. – Лань : электронно-библиотечная система. – Режим доступа: <https://e.lanbo-ok.com/book/210455> – 16.12.2025.

5 Волкова, Е. Д. Методы экспресс-анализа безопасности овощей и фруктов [Электронный ресурс] : учеб. пособие / Е. Д. Волкова. – Санкт-Петербург : СПбГАУ, 2021. – 92 с. – Режим доступа: <https://ebooks.spbgau.ru/45632> – 18.12.2025.

6 Горбунов, П. С. Методы компьютерного зрения в оценке качества фруктов и овощей [Электронный ресурс] : учеб.-метод. пособие / П. С. Горбунов. – Новосибирск : НГАУ, 2022. – 45 с. – Режим доступа: https://elibrary.nsa-u.ru/files/veg_quality.pdf – 19.12.2025.

7 Гришин, А. А.; Карпов, В. П. Автоматизированные линии сортировки плодов с компьютерным зрением [Монография] / А. А. Гришин, В. П. Карпов. – Москва : Машиностроение, 2020. – 208 с.

8 Дмитриев, П. С. Бесконтактные методы оценки спелости фруктов [Электронный ресурс] / П. С. Дмитриев. – Казань : КНИТУ, 2023. – 67 с. – Режим доступа: https://kpfu.ru/staff_files/789654.pdf – 18.12.2025.

9 Ермаков, В. Г. Мультиспектральная визуализация агроаналитике: монография / В. Г. Ермаков. – Новосибирск : СО РАН, 2021. – 154 с.

10 Жуков, Р. О. Программное обеспечение для анализа качества овощей [Электронный ресурс] : учеб.-метод. пособие / Р. О. Жуков. – Воронеж : ВГТУ, 2022. – 58 с. – Режим доступа: <https://window.edu.ru/resource/672/84672> – 18.12.2025.

11 Иванов, Д. А. Автоматизированные системы контроля качества сельхозпродукции [Электронный ресурс] : учебное пособие / Д. А. Иванов. – Казань : КГАУ, 2019. – 67 с. – Лань : электронно-библиотечная система. – Режим доступа: <https://e.lanbook.com/book/175432> – 16.05.2025.

12 Ильин, С. К. Глубинное обучение для классификации дефектов фруктов [Электронный ресурс] / С. К. Ильин. – Томск : ТПУ, 2023. – 84 с. – Режим доступа: <https://core.ac.uk/download/567832345.pdf> – 18.05.2025.

13 Королев, Д. В. Роботизированные системы для переработки овощей / Д. В. Королев. – Москва : Росинформагротех, 2021. – 187 с.

14 Кузнецов, С. В. Искусственный интеллект в сельском хозяйстве: методы и приложения [Электронный ресурс] : учебно-методическое пособие / С. В. Кузнецов. – Москва : МСХА, 2023. – 94 с. – Лань : электронно-библиотечная система. – Режим доступа: <https://e.lanbook.com/book/225678> – 16.05.2025.

15 Лапин, О. Н. Методы ИК-спектроскопии в контроле качества фруктов [Электронный ресурс] : учеб. пособие / О. Н. Лапин. – Краснодар : КубГАУ, 2022. – 72 с. – Режим доступа: <https://elibrary.kubgau.ru/4567> – 18.05.2025.

16 Лаптев, В. Г.; Морозова, Е. А. Дистанционные методы мониторинга состояния растений [Электронный ресурс] : учебное пособие / В. Г. Лаптев, Е. А. Морозова. – Воронеж : ВГАУ, 2021. – 78 с. – Лань : электронно-

библиотечная система. – Режим доступа: <https://e.lanbook.com/book/203421> – 16.05.2025.

17 Миронов, А. А. Технологии машинного обучения для сортировки фруктов [Монография] / А. А. Миронов. – Москва : Агропромиздат, 2022. – 210 с.

18 Морозов, В. П. Цифровые технологии в постурожайной обработке [Монография] / В. П. Морозов. – Санкт-Петербург : ПрофиКС, 2020. – 165 с.

19 Зайцев, М. И. Сенсоры для мониторинга свежести плодов [Монография] / М. И. Зайцев. – Москва : Энергия, 2020. – 132 с.

20 Зайцева, М. К.; Козлов, В. П. Применение спектроскопии в пищевой промышленности [Электронный ресурс] : учебное пособие / М. К. Зайцева, В. П. Козлов. – Санкт-Петербург : СПбГАУ, 2020. – 112 с. – Лань : электронно-библиотечная система. – Режим доступа: <https://e.lanbook.com/book/198765> – 16.05.2025.

21 Тарасова, Е. В. Методы машинного обучения для прогнозирования сроков хранения фруктов [Электронный ресурс] / Е. В. Тарасова. – Москва : РГАУ-МСХА, 2023. – 89 с. – Режим доступа: <https://e.lanbook.com/book/245678> – 20.05.2025.

22 Ушаков, Д. Н. Беспроводные сенсорные сети в мониторинге овощехранилищ [Монография] / Д. Н. Ушаков. – Санкт-Петербург : ПрофиКС, 2022. – 156 с.

23 Федоров, А. П. Алгоритмы обработки тепловых изображений плодов [Электронный ресурс] : учеб. пособие / А. П. Федоров. – Казань : КНИТУ, 2023. – 78 с. – Режим доступа: https://kpfu.ru/staff_files/856743.pdf – 20.05.2025.

24 Харитонов, В. Г.; Сидорова, Л. М. Роботизированные комплексы для сортировки ягод [Монография] / В. Г. Харитонов, Л. М. Сидорова. – Москва : АгроНаука, 2021. – 192 с.

25 Цветков, И. Б. Методы спектрального анализа для определения нитратов в овощах [Электронный ресурс] / И. Б. Цветков. – Новосибирск :

НГАУ, 2022. – 65 с. – Режим доступа:
https://elibrary.nsau.ru/files/nitrates_analysis.pdf – 20.05.2025.

26 Чернов, М. П. Системы компьютерного зрения для тепличных комплексов [Монография] / М. П. Чернов. – Москва : Агропромиздат, 2023. – 178 с.

27 Шапошников, А. А. Нейросетевые методы классификации дефектов картофеля [Электронный ресурс] : учеб.-метод. пособие / А. А. Шапошников. – Воронеж : ВГАУ, 2022. – 72 с. – Режим доступа:
<https://window.edu.ru/resource/782/93782> – 20.05.2025.

28 Щукин, К. В. Умные технологии в логистике овощей и фруктов [Монография] / К. В. Щукин. – Санкт-Петербург : Питер, 2021. – 165 с.

29 Яковлев, П. Д. Методы мультиспектральной съемки для оценки зрелости плодов [Электронный ресурс] / П. Д. Яковлев. – Краснодар : КубГАУ, 2023. – 84 с. – Режим доступа: <https://elibrary.kubgau.ru/5678> – 20.05.2025.

30 Янченко, В. Г. Автоматизированные системы контроля качества винограда [Монография] / В. Г. Янченко. – Москва : Пищепромиздат, 2022. – 143 с.