

А. Н. Юрин

*РУП «НПЦ НАН Беларуси по механизации сельского хозяйства»
г. Минск, Республика Беларусь
E-mail: anton-jurin@rambler.ru*

РАЗРАБОТКА АРХИТЕКТУРЫ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ СИСТЕМЫ ТЕХНИЧЕСКОГО ЗРЕНИЯ ДЛЯ СОРТИРОВКИ ЯБЛОК

Аннотация. Статья посвящена актуальности создания технического средства для автоматизации процесса сортировки яблок, в частности, основного ее элемента – системы технического зрения.

В статье представлено обоснование способа обучения искусственной нейронной сети (ИНС) дефектам плодов, предложена её архитектура для решения данной задачи, обоснованы критерии оценки точности и полноты распознавания дефектов, а также приведены результаты функционирования системы технического зрения (СТЗ) с применением предложенной ИНС.

Разработанная СТЗ внедрена в линию сортировки и фасовки яблок ЛСП-4, успешно прошедшую приемочные испытания и производственную проверку в ОАО «Остромечево» Брестской области. В ходе приемочных испытаний линии ЛСП-4 установлено, что она обеспечивает точность сортировки по размеру 75,4 %, по наличию дефектов – 73,1 % и производительность труда – 1,8 т/ч.

Ключевые слова: сортировка яблок, дефекты плодов, обучающая выборка, парша, гниль, нажим, прокол.

Anton N. Yuryn

*RUE “SPC NAS of Belarus for Agricultural Mechanization”
Minsk, Republic of Belarus
E-mail: anton-jurin@rambler.ru*

DEVELOPMENT OF AN ARTIFICIAL NEURAL NETWORK ARCHITECTURE OF A TECHNICAL VISION SYSTEM FOR SORTING APPLES

Abstract. The article is devoted to the relevance of creating a technical tool for automating the apple sorting process, in particular, its main element – a technical vision system. The article presents the rationale for the method of training an artificial neural network (ANN) for fruit defects, proposes its architecture for solving this problem, substantiates the criteria for assessing the accuracy and completeness of defect recognition, and also presents the results of the operation of a technical vision system (VS) using the proposed ANN.

The developed technical vision system was introduced into the LSP-4 apple sorting and packaging line, which successfully passed acceptance tests and production inspection at Ostromechevo OJSC, Brest region. During acceptance tests of the LSP-4 line, it was found that it ensures sorting accuracy by size of 75.4 %, by the presence of defects – 73.1 % and labor productivity – 1.8 t/h.

Keywords: apple sorting, fruit defects, training set, scab, rot, pressure, puncture.

Введение

Обязательной операцией при товарной обработке плодов является сортирование, в процессе которого продукцию разделяют на сорта по качеству в зависимости от размера и наличия дефектов. Эта операция осуществляется, как правило, вручную при визуальном осмотре плодов рабочими, что требует большого количества ручного труда [1–6]. В настоящее время на данную операцию приходится до 70 % всех трудозатрат товарной обработки плодов.

Использование автоматизированных сортировальных машин для идентификации и разделения плодов на сорта позволяет значительно повысить качество сортирования и производительность.

Наиболее подходящим для автоматизации способом идентификации качества плодов является метод оптического контроля, поскольку он обеспечивает высокую точность оценки качества и соответствует условиям технологии.

Поэтому создание оптико-электронной системы (в дальнейшем – ОЭС), позволяющей определить качество поверхности плода без его повреждения, по аналогии с тем, как это делает человек [7–13], является важной агроинженерной задачей.

Цель исследования – повышение эффективности садоводства Республики Беларусь посредством внедрения в производство СТЗ для автоматизированной сортировки яблок по размеру и наличию дефектов.

Задачи исследования – обоснование конструктивно-технологической схемы и основных параметров ОЭС, разработка алгоритма её функционирования и программного обеспечения, проведение испытаний.

Материалы и методы. Исследованиями предусматривалось проведение лабораторных опытов по распознаванию дефектов яблок и производственных испытаний изготовленной на основе исследований технологической линии сортировки и фасовки яблок ЛСП-4. Для создания обучающей выборки помологических особенностей и дефектов плодов использованы плоды урожая 2020–2021 гг. производства ОАО «Остромечеве» сортов «Имант», «Вербное» и «Глостер», а также была создана лабораторная установка системы технического зрения, включающая в себя оптический модуль со структурной подсветкой, стол с вращающимися роликами и электронный блок управления.

Результаты и их обсуждение

Глубокое обучение нейронной сети. Глубокое обучение – это класс методов машинного обучения, в котором признаки для классификации образов определяются и задаются не вручную, а автоматически генерируются с помощью математических моделей – ИНС [1, 2]. Технически обучение ИНС заключается в нахождении коэффициентов связей (весов) между нейронами. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходными, а также выполнять обобщение. Под термином «обобщение» понимается способность ИНС на основе обучающей выборки генерировать правильный ответ при анализе входных данных, которые не встречались в процессе обучения. Схематически процесс обучения ИНС представлен на рис. 1.




Рис. 1. Процесс обучения ИНС

Способность моделей глубокого обучения автоматически выделять признаки для классификации образов приводит к тому, что для их обучения требуется большой объем обучающих данных, который значительно превышает объем, достаточный для обучения других, классических моделей машинного обучения. Для оптимизации процесса формирования обучающей выборки создаются открытые базы данных размером в миллионы цифровых изображений. Однако при решении конкретных практических задач нередки случаи, когда в базах данных отсутствуют изображения, содержащие искомые для конкретной технической задачи эталонные образы. Это требует использования других подходов к формированию обучающей выборки: на основе реальных изображений; на основе синтетических изображений; из синтетических данных, сгенерированных на основе реальных изображений.

Кроме обучающих данных, необходимо также построить архитектуру ИНС, приемлемую для решения конкретной задачи. Для задачи распознавания дефектов на изображениях яблок исполь-

зуются ИНС, называемые детекторами. Детекторы способны указать местоположение объекта на изображении и его класс. Учеными предложено множество архитектур детекторов. Самыми популярными из них являются SSD (Single Shot MultiBox Detector) [3], R-FCN (Region-based Fully Convolutional Networks) [4] и Faster RCNN (Faster Region-based Convolutional Neural Networks) [5]. Эти детекторы обладают разными характеристиками быстродействия и точности. В работе [6] детекторы были обучены на наборе данных COCO dataset и протестированы. Результаты исследования представлены на рис. 2.




Рис. 2. Сравнительные характеристики детекторов

По вертикальной оси представлены значения оценки средней точности работы детектора, по горизонтальной оси – быстродействие работы. Самым быстрым оказался детектор SSD на основе нейронной сети MobileNet, а самым точным – детектор Faster R-CNN на основе нейронной сети Inception Resnet V2. Так как задача сортировки яблок на конвейере требует высокой точности результатов, то для реализации алгоритма распознавания дефектов был выбран детектор Faster R-CNN Resnet V2.

Архитектура детектора Faster R-CNN по сути является комбинацией двух нейронных сетей: детектора Fast R-CNN и нейронной сети, предсказывающей ограничивающие объекты прямоугольники, называемой RPN [4] (рис. 3).

Работу детектора можно разделить на несколько шагов.

Шаг 1. Получить из входного изображения карту свойств, используя любую сверточную сеть без последних полносвязных слоев, служащих для классификации.




Рис. 3. Архитектура детектора Faster R-CNN

Шаг 2. Получить ограничивающие объекты прямоугольники, используя сеть RPN (рис. 4).

На вход сети RPN поступает карта свойств, полученная на предыдущем шаге, на выходе – координаты ограничивающих прямоугольников, в которых предположительно содержится объект, и вероятности нахождения объекта в предложенных ограничивающих прямоугольниках.



Рис. 4. Архитектура нейронной сети RPN

RPN – это небольшая полносвязная сверточная нейронная сеть, состоящая из сверточного слоя размером $n \times n$, за которым следуют два параллельных полносвязных сверточных слоя размером 1×1 , используемые для классификации и регрессии. Для генерации ограничивающих прямоугольников сеть использует небольшое скользящее окно размером $n \times n$ над картой свойств, которое генерирует k прямоугольников разных размеров и пропорций, называемых анкерами. Небольшая часть карты свойств, ограниченная анкерами, поступает на слои классификации и регрессии для предсказания ограничивающих прямоугольников и вероятностей нахождения в них объектов. Таким образом, на выходе слоя регрессии получается $4k$ координаты ограничивающих прямоугольников, а на выходе слоя классификации – $2k$ вероятностей нахождения объекта в ограничивающем прямоугольнике. Авторы предлагают брать $k = 9$ и $n = 3$.

Шаг 3. Классифицировать ограничивающие прямоугольники, полученные на шаге 2, используя карту свойств, полученную на шаге 1, также уточнить координаты ограничивающих прямоугольников.

После формирования обучающей выборки и выбора подходящей архитектуры ИНС можно приступить к непосредственному ее обучению. Для этого на вход ИНС поочередно подаются изображения обучающей выборки, а на выход – их разметка, т. е. координаты ограничивающих прямоугольников и соответствующие им классы. Необученная ИНС, пропуская через себя входное изображение, генерирует координаты ограничивающих прямоугольников и соответствующие им вероятности принадлежности объектов классам. Затем выход, полученный необученной ИНС, сравнивается с эталонным выходом, получая оценку схожести, и методом обратного распространения ошибки параметры нейронов ИНС корректируются таким образом, чтобы минимизировать оценку схожести. Обучение останавливается тогда, когда эта оценка достигает заранее установленного порога.

В итоге результатом процесса обучения является ИНС, которая на вход будет получать изображение, поступающее от камеры, а на выходе будет выдавать список повреждений яблока вместе с их координатами, если таковые имеются.

Для задачи распознавания дефектов на изображениях яблок используются ИНС, называемые детекторами. Детекторы способны указать местоположение объекта на изображении и его класс. Анализ работы детекторов, проведенный в работе [14], показал, что подходящей для выполняемой работы является сегментационная сеть `lraspp mobilenetV3` из пакета `mmsegmentation PyTorch`.

Функция потерь `CrossEntropyLoss`, optimizer Adam (learning rate 0.01).

Для каждого объекта в выборке возможны 4 ситуации:

– правильное предсказание положительной метки. Такие объекты относятся к группе true positive (TP);

- ошибочное предсказание положительной метки – false positive (FP);
- правильное предсказание отрицательной метки – true negative (TN);
- ошибочное предсказание отрицательной метки – false negative (FN).

Для оценки качества работы детектора использовали метрики IoU и Accuracy.

Метрика Accuracy является величиной, обозначающей долю правильных ответов алгоритма, значение которой определялось по формуле:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}.$$

Метрика Intersection over Union (IoU) – величина, показывающая, насколько у двух объектов (эталонного и текущего) совпадает внутренняя площадь:

$$\text{IoU} = \frac{pBB}{tBB},$$

где tBB – реальная площадь объекта; pBB – площадь объекта, предсказанная детектором.

Обучение нейронной сети происходило до 400 эпох. Значения метрик для различных дефектов, распознанных нейронной сетью, представлены в табл. 1.

Таблица 1. Значение метрик IoU и Accuracy для различных дефектов яблок

Класс	IoU	Accuracy
Apple (яблоко)	0.981	0.975
Background (фон)	0.932	0.967
«Point»	0.857	0.874
«Pressure»	0.744	0.858
«Hail»	0.691	0.785
«Rot»	0.798	0.764
«Scratch»	0.774	0.741
«Scab»	0.815	0.772
«Spotting»	0.753	0.734
«Lumps»	0.716	0.758
«Net»	0.759	0.682
«Wart»	0.703	0.697
Среднее значение	0.793	0.8

Как видно из таблицы, наибольшие значения показателей метрик соответствуют дефектам «нажим», «гниль», «парша» в виде точек, а наименьшие – сетка, градобоина. Это объясняется меньшим объемом обучающей выборки именно этих дефектов яблок.

Значения метрики Accuracy при определении сорта яблок обученной нейронной сетью приведены в табл. 2.

Таблица 2. Значения метрики Accuracy при определении сорта яблок обученной нейронной сетью

Сорт яблок	Accuracy
Высший	0.763
Первый	0.825
Второй	0.851
Бессортной	0.864

Реализация результатов исследований. Результаты исследований использованы при создании технологической линии сортировки и фасовки яблок ЛСП-4, разработанной РУП «Научно-практический центр НАН Беларуси по механизации сельского хозяйства».



Рис. 5. Технологическая линия сортировки и фасовки яблок ЛСП-4 на испытаниях в ОАО «Остромечев»

Приемочные испытания линии проведены в ОАО «Остромечев» Брестского района в 2020–2021 годах. По результатам приемочных испытаний линии ЛСП-4 получен положительный протокол от 25.02.2022 № 004-1/3-2022 [15].

Анализ результатов испытаний показал, что технологическая линия соответствует требованиям технического задания и обеспечивает качественное выполнение технологического процесса сортировки яблок по размеру и наличию дефектов от механических повреждений, болезней и вредителей. При этом точность сортирования плодов по размеру составила 75,4 %, а точность сортирования по размеру и наличию дефектов – 73,1 %. Производительность линии составила 1,8 т/ч. Наибольшая точность распознавания обеспечивается при определении дефектов «pressure» и «point» (83 и 85 % соответственно), а наименьшая – для «net» и «wart» (73 и 72 % соответственно). Очевидно, для повышения точности распознавания дефектов плодов необходимо увеличение обучающей выборки не менее чем в 2–3 раза.

Выводы

Результаты исследований внедрены в технологической линии сортировки и фасовки яблок ЛСП-4 разработки РУП «НПЦ НАН Беларуси по механизации сельского хозяйства», которая обеспечивает точность сортирования плодов по размеру на 75,4 %, а точность по наличию дефектов – на 73,1 %.

Благодарности. Работа выполнялась в рамках задания 5 «Разработать и освоить производство технологической линии сортировки и фасовки яблок» подпрограммы «Белсельхозмеханизация-2025» государственной научно-технической программы «Инновационные агропромышленные и продовольственные технологии» 2021–2025 гг.

Список использованных источников

1. Гурьянов, Д. В. Распознавание качества плодов / Д.В. Гурьянов // Робототехника в сельскохозяйственных технологиях : материалы Междунар. науч.-практ. конф., 10–12 нояб. 2014 г. / Мичур. гос. аграр. ун-т. – Мичуринск, 2014. – С. 177–182.
2. Применение методов люминесцентного анализа в системах технического зрения при сортировании плодов / М. В. Кирина [и др.] // Робототехника в сельскохозяйственных технологиях : материалы Междунар. науч.-практ. конф., 10–12 нояб. 2014 г. / Мичур. гос. аграр. ун-т. – Мичуринск, 2014. – С. 188–191.
3. Лакомов, Д. В. Обработка изображений при распознавании образов сельскохозяйственной продукции / Д. В. Лакомов // Цифровизация агропромышленного комплекса : сб. науч. ст. I Междунар. науч.-практ. конф., Тамбов, 10–12 окт. 2018 г. : в 2 т. / Тамб. гос. техн. ун-т [и др.]. – Тамбов, 2018. – Т. 1. – С. 261–263.
4. Рудник, Ю. А. Робототехническая система для сортирования яблок / Ю. А. Рудник, С. В. Журавлев // Робототехника в сельскохозяйственных технологиях : материалы Междунар. науч.-практ. конф., 10–12 нояб. 2014 г. / Мичур. гос. аграр. ун-т. – Мичуринск, 2014. – С. 32–34.

5. Разработка алгоритмов системы распознавания ягод земляники садовой при роботизированном сборе / Д. О. Хорт [и др.] // Электротехнологии и электрооборудование в АПК. – 2020. – № 1 (38) – С. 133–141.
6. Гурьянов, Д. В. Повышение эффективности сортирования яблок на основе цветных телевизионных датчиков : дис. ... канд. техн. наук: 05.20.02/ Д. В. Гурьянов. – Мичуринск, 2004. – 199 с.
7. Ganganagowdar, N.V. An intelligent computer vision system for vegetables and fruits quality inspection using soft computing techniques / N. V. Ganganagowdar, A. V. Gundad // Agr. Engineering Intern.: Agr. Engineering Intern.: CIGR J. – 2019. – Vol. 21, N 3. – P. 171–178.
8. Lu, Y. Development of a multispectral Structured Illumination Reflectance Imaging (SIRI) system and its application to bruise detection of apples / Y. Lu, R. Lu // Trans. of the ASABE. – 2017. – Vol. 60, N 4. – P. 1379–1389.
9. Новые технологии и технические средства для механизации работ в садоводстве / И. М. Куликов [и др.]. – М.: ФГБНУ «Росинформагротех», 2012. – 164 с.
10. Training deep face recognition systems with synthetic data / A. Kortylewski [et al.] // Cornell University Library [Электронный ресурс]. – 2018. – Режим доступа: <https://arxiv.org/pdf/1802.05891.pdf>. – Дата доступа: 16 April 2018.
11. Чигорин, А. Классификация автодорожных знаков на основе сверточной нейросети, обученной на синтетических данных / А. Чигорин, Б. Моисеев // The 22nd International Conference on Computer Graphics and Vision, Москва, Россия, 1–5 октября 2012 г. – С. 284–287.
12. Жиркова, А. А. Автоматизированная система гиперспектрального контроля дефектов яблок / А. А. Жиркова, П. В. Балабанов, А. Г. Дивин // Современная наука: теория, методология, практика : материалы III Всерос. (нац.) науч.-практ. конф., Тамбов, 13–14 апр. 2021 г. / Тамб. гос. техн. ун-т ; редкол.: П. В. Монастырев [и др.]. – Тамбов, 2021. – С. 291–296.
13. Роботизированный комплекс для сортировки яблок / П.В. Балабанов [и др.] // Цифровизация агропромышленного комплекса сб. науч. ст. II Междунар. науч.-практ. конф., Тамбов, 21–23 окт. 2020 г. : в 2 т. / Тамб. гос. техн. ун-т [и др.]. – Тамбов, 2020. – Т. 2. – С. 44–47.
14. Huang, J. Speed/accuracy trade-offs for modern convolutional object detectors [Electronic resource] / J. Huang // Cornell University Library [Электронный ресурс]. – 2016. – Mode of access: <https://arxiv.org/pdf/1611.10012.pdf>. – Date of access: 04.06.2019.
15. Протокол приемочных испытаний технологической линии сортировки и фасовки яблок ЛСП-4 : № 004 1/3-2022. – Введ. 25.02.2022. – п. Привольный : ГУ «Белорусская МИС».