

Научная статья
УДК 634.11:581.4:004.93
<https://doi.org/10.24412/1992-2582-2026-2-31-38>

ЦИФРОВАЯ ДЕТЕКЦИЯ И КЛАССИФИКАЦИЯ ВЕГЕТАТИВНЫХ И ГЕНЕРАТИВНЫХ ПОЧЕК ЯБЛОНИ НА ОСНОВЕ АНАЛИЗА МИКРОСКОПИЧЕСКИХ ИЗОБРАЖЕНИЙ

Ирина Владимировна Ариничева^{1✉}, Татьяна Николаевна Дорошенко², Юлия Андреевна Онищенко³

¹⁻³Кубанский государственный аграрный университет имени И.Т. Трубилина, Краснодар, Россия

¹loukianova7@mail.ru✉

Аннотация. Продуктивность яблони напрямую связана с количеством заложённых генеративных почек и характером их последующего развития. Отсюда следует практическая необходимость в своевременной диагностике состояния почек при планировании агротехнических мероприятий осенне-весеннего периода в многолетних насаждениях. На сегодняшний день идентификацию типов почек проводят в основном вручную; работа требует высокой квалификации, при этом визуально различить вегетативные и генеративные почки, особенно на ранних этапах органогенеза, бывает непросто даже опытному специалисту. Цель исследования – разработать метод цифровой детекции и классификации вегетативных и генеративных почек яблони по микроскопическим изображениям. Была использована платформа Teachable Machine для оценки принципиальной возможности автоматизации такого определения и применения его результатов для поддержки агротехнических решений. Материал – почки шести сортов яблони: Гала, Голден Делишес, Ренет Симиренко, Кубанское багряное, Флорина, Либерти. Фотосъёмку вели в период покоя растений (ноябрь–февраль) в контролируемых условиях с помощью бинокулярного микроскопа при увеличении 7×. Сформирована размеченная выборка из 1121 изображения вегетативных и генеративных почек на пяти последовательных этапах органогенеза. Построенная на его основе модель показала общую точность классификации около 0,91, среднюю F1-меру – порядка 0,89. Лучшее всего модель распознаёт вегетативные почки и поздние этапы органогенеза; для ранних и переходных стадий точность несколько ниже, что, вероятно, объясняется морфологической близостью признаков и неравномерностью распределения данных в обучающей выборке. Полученные результаты свидетельствуют, что методы компьютерного зрения могут быть эффективно применены для автоматической диагностики этапов органогенеза яблони. Предложенный подход перспективен для использования в системах цифрового мониторинга плодовых культур, при автоматизации морфологических исследований, а также в технологиях точного садоводства и роботизированной обрезки.

Ключевые слова: яблоня, вегетативные и генеративные почки, органогенез, агроприемы, точное садоводство, автоматическая диагностика, цифровая детекция, компьютерное зрение, машинное обучение

Для цитирования: Ариничева И.В., Дорошенко Т.Н., Онищенко Ю.А. Цифровая детекция и классификация вегетативных и генеративных почек яблони на основе анализа микроскопических изображений // Вестник Мичуринского государственного аграрного университета. 2026. № 2(85). С. 31-38. <https://doi.org/10.24412/1992-2582-2026-2-31-38>.

Original article

DIGITAL DETECTION AND CLASSIFICATION OF VEGETATIVE AND GENERATIVE APPLE BUDS BASED ON MICROSCOPIC IMAGE ANALYSIS

Irina V. Arinicheva¹, Tatyana N. Doroshenko², Yulia A. Onishchenko²

¹⁻³Kuban State Agrarian University named after I.T. Trubilina, Krasnodar, Russia

¹loukianova7@mail.ru✉

Abstract. Apple tree productivity is directly related to the number of generative buds set and the nature of their subsequent development. This necessitates timely diagnosis of bud condition when planning agronomic interventions for the fall and spring in perennial plantings. Currently, bud type identification is primarily performed manually; this requires high skill, and visually distinguishing between vegetative and generative buds, especially in the early stages of organogenesis, can be challenging even for experienced specialists. The aim of the study was to develop a method for digitally detecting and classifying vegetative and generative apple buds using microscopic images. The Teachable Machine platform was used to evaluate the fundamental feasibility of automating such detection and applying its results to support agricultural decisions. The material consisted of buds from six apple varieties: Gala, Golden Delicious, Renet Simirenko, Kubanskoye Bagryanoye, Florina, and Liberty. Photographs were taken during the plant dormancy period (November–February) under controlled conditions using a binocular microscope at 7× magnification. A labeled sample of 1,121 images of vegetative and generative buds at five consecutive stages of organogenesis was created. The resulting model demonstrated an overall classification accuracy of approximately 0,91 and an average F1 score of approximately 0,89. The model best recognizes vegetative buds and late stages of organogenesis; accuracy is somewhat lower for early and transitional stages, likely due to the morphological similarity of the features and the uneven distribution of data in the training set. The obtained results indicate that computer vision methods can be effectively applied to the automatic diagnosis of apple tree organogenesis stages. The proposed approach is promising for use in digital fruit crop monitoring systems, automated morphological studies, and precision gardening and robotic pruning technologies.

Keywords: apple tree, vegetative and generative buds, organogenesis, agricultural practices, precision gardening, automatic diagnostics, digital detection, computer vision, machine learning

For citation: Arinicheva I.V., Doroshenko T.N., Onishchenko Yu.A. Digital detection and classification of vegetative and generative apple buds based on microscopic image analysis. Bulletin of Michurinsk State Agrarian University, 2026, no. 2(85), pp. 31-38. <https://doi.org/10.24412/1992-2582-2026-2-31-38>.

Введение. Яблоня (*Malus domestica* Borkh.) является одной из наиболее распространенных плодовых культур в мире [1]. В отличие от периода 2014-2019 гг., когда валовой сбор яблок в России колебался в районе 1,5-1,9 млн тонн, с 2020 года отрасль вышла на принципиально новый уровень, стабильно преодолевая планку в 2 млн тонн, за исключением неурожайных лет. Благодаря этой динамике наша страна уверенно движется к цели, поставленной президентом РФ В.В. Путиным, – достичь полной самообеспеченности яблоками к 2028 году, для чего необходимо ежегодное производство плодов около 2,5 млн тонн [2, 3].

Однако на сегодняшний день в яблоневых садах по-прежнему многое держится на ручном труде. Такая работа требует от специалиста серьёзного практического опыта, занимает много времени, увеличивает себестоимость продукции и не застрахована от ошибок – человеческий фактор даёт о себе знать. Переход к точному земледелию предполагает активное использование информационных технологий, в том числе для объективного фенотипирования. Один из эффективных инструментов здесь – визуализация растений, позволяющая быстро, без особых затрат, объективно получать метрические характеристики. Компьютерное зрение уже применяют для решения самых разных задач плодового садоводства, например, оценивают количество и размер плодов на дереве [4-6], распознают цветки яблони [7-9], идентифицируют ветви [15, 16], проводят детекцию качества [10-14] и степени зрелости плодов [17-19], а также автоматизируют сбор урожая [20, 21].

Продуктивность яблони в первую очередь определяется количеством нормально развивающихся генеративных (цветковых) почек на дереве [22, 23]. Соответственно, и агротехнические приёмы, которые применяют в разные фазы вегетации и в период покоя, должны быть направлены на то, чтобы этот показатель оптимизировать. Для правильной обрезки, регулирования нагрузки урожаем и достижения планируемых объёмов и качества плодов необходимо точно различать цветковые и вегетативные почки. Однако их морфологическое сходство делает такую классификацию непростой задачей. Таким образом, разработка системы автоматического распознавания почек яблони не просто актуальна, но, возможно, один из ключевых шагов на пути к внедрению технологий точного садоводства.

В последние годы глубокие сверточные нейронные сети (DCNN) продемонстрировали впечатляющие результаты в различных областях, связанных с мультимедиа, применяемой для детекции и классификации изображений [6,

7]. В отличие от традиционных подходов, основанных на ручном создании специфических признаков, DCNN обеспечивает автоматическое извлечение признаков и их иерархическое обучение непосредственно из набора данных изображений, демонстрируя стабильно высокие результаты для большинства задач компьютерного зрения [8-11].

Параллельно с развитием сложных архитектур нейронных сетей, в последние годы активно развиваются инструменты, демократизирующие доступ к технологиям машинного обучения. Одним из таких инструментов является платформа Teachable Machine, разработанная Google. Teachable Machine, представляет собой веб-инструмент, позволяющий создавать модели машинного обучения на основе изображений, звуков и поз без необходимости написания программного кода. Платформа функционирует непосредственно в браузере, что обеспечивает ее доступность и не требует наличия специализированного аппаратного или программного обеспечения. Несмотря на простоту использования, Teachable Machine находит применение не только в образовательных целях, но и в решении прикладных научных задач. Сравнительные исследования показывают, что Teachable Machine может превосходить по точности такие архитектуры, как MobileNet и YOLO, в задачах обнаружения объектов [12-14].

Целью исследования являлась разработка метода цифровой детекции и классификации вегетативных и генеративных почек яблони на основе микроскопических изображений с использованием платформы Teachable Machine для оценки возможности автоматизации их определения и поддержки принятия агротехнических решений.

Материалы и методы исследований. Исследование проводилось в 2025-2026 гг. в насаждениях яблони учебно-опытного хозяйства «Кубань» Кубанского ГАУ (почва – чернозем выщелоченный). Изучали сорта яблони: Гала, Голден Делишес, Ренет Симиренко, Кубанское багряное, Флорина, Либерти, привитые на подвое М9. Отбор образцов почек проводился в период покоя растений – с ноября по февраль.

Для изучения морфологии почек с помощью микроскопического анализа использовался бинокулярный микроскоп с увеличением 7×. Почки препарировались и фотографировались на белом фоне с последующим сохранением изображений в цифровом формате. В результате было получено 1121 изображений почек (рисунок 1).




Рисунок 1. Микроскопическое изображение генеративных почек яблони сорта Голден Делишес на I этапе органогенеза, ноябрь 2025 г.

Figure 1. Microscopic image of the generative buds of the Golden Delicious apple tree at the I stage of organogenesis, November 2025.

Классификация почек проводилась следующим образом. Почки были разделены на определенные категории. Создан датасет вегетативных почек – vegetative. Датасет генеративных почек формировался по пяти этапам органогенеза – это generative1, generative2, generative3, generative4, generative5.

В основу периодизации развития легли морфологические признаки – от преобразования плоской апикальной меристемы в куполообразную структуру до формирования пестика [22, 23] (таблица 1).

Таблица 1
Table 1Итоговая структура дата сета
Final structure of the date set

Класс	Количество изображений	Характеристика группы
vegetative	122	Почка находится в состоянии относительного покоя или активного вегетативного роста. Конус нарастания вытянутый, узкий. Закладываются только листовые зачатки, генеративные органы отсутствуют. Это типичное состояние ростовых (вегетативных) почек, а также генеративных почек до начала их дифференциации.
generative1	209	Переход конуса нарастания от вегетативного состояния к генеративному. Конус нарастания становится более округлым и широким. Начинается дифференциация первых цветковых бугорков (зачатков цветков) в пазухах кроющих листьев. Внутри почки формируются зачатки соцветия (чаще всего щитка). Это этап начала закладки цветковых меристем.
generative2	198	Происходит закладка и дифференциация органов первого круга цветка – чашелистиков (сепалий). Цветковые бугорки обособляются, на их верхушке формируются первичные бугорки чашечки. Чашелистики начинают приобретать характерную форму. Продолжается рост оси соцветия и цветоножек.
generative3	324	Закладываются лепестки (петалии). Они возникают в виде бугорков внутри от чашелистиков. В этот период хорошо различимы все элементы околоцветника. Продолжается дифференциация цветков, формируются нектарники у основания цветоноса у яблони.
generative4	162	Наступает закладка андроеца – тычинок. Они образуются в виде бугорков внутри от лепестков. Происходит дифференциация тычиночных нитей и пыльников. В пыльниках формируются материнские клетки микроспор. Этот этап важен для последующего формирования пыльцы.
generative5	106	Завершающий этап органогенеза цветка. Закладывается гинецей – пестик (у яблони обычно 5-гнездная завязь). Формируются столбик, рыльце и семязачатки внутри завязи. К концу этого этапа все органы цветка полностью сформированы, и почка переходит в состояние зимнего покоя уже с дифференцированными цветками.

Обучение модели осуществлялось на основе сверточной нейронной сети MobileNet, используемой в качестве базовой архитектуры для извлечения признаков. Выбор данной модели обусловлен рядом её архитектурных преимуществ, значимых для решения поставленной задачи. Прежде всего, MobileNet относится к классу легковесных сверточных сетей, оптимизированных для работы при ограниченных вычислительных ресурсах, что позволяет выполнять как обучение, так и инференс непосредственно в браузере без существенных потерь производительности, что особенно важно для исследования биологических систем. Кроме того, важным преимуществом является применение механизма переноса обучения: предобученная

на крупном наборе данных ImageNet модель используется в качестве основы, при этом её финальный классификационный слой удаляется, а выход предыдущего слоя служит универсальным дескриптором изображения. Такой подход обеспечивает возможность эффективного дообучения на специализированной выборке микроскопических изображений почек яблони даже при относительно небольшом объёме данных, что особенно важно для корректного представления пяти этапов органогенеза.

Изображения были разделены на обучающую и тестовую выборки, причем тестовые изображения не использовались при обучении (таблица 2).

Таблица 2
Table 2Разделение собранной выборки
Division of the collected sample

Набор данных	Количество изображений	Доля от общей выборки, %
Обучающий (Train)	~785	70 %
Тестовый (Test)	~336	30 %
Итого:	~1121	

Каждое тестовое изображение подается на вход модели, которая выдаёт предсказанный класс – этап (рисунок 2).




Рисунок 2. Классификация этапа развития генеративных почек
Figure 2. Classification of the stage of generative bud development

После завершения обучения платформа предоставляет пользователю набор визуализированных метрик, доступных через интерфейс. В частности, в Teachable Machine отображается матрица ошибок (confusion matrix) – кросс-таблица, в которой строки соответствуют фактическим классам, а столбцы – предсказаниям модели (рисунок 3). Такая визуализация позволяет определить, какие именно классы (в нашем случае, вегетативные и генеративные почки на разных этапах органогенеза) модель чаще всего путает, и выявить категории, представляющие наибольшую сложность для распознавания.

Анализ матрицы ошибок показал высокую точность классификации для большинства классов, что подтверждается преобладанием значений на главной диагонали. Наиболее значимые ошибки наблюдаются между классами 2 и 4, что может быть связано с их морфологической близостью. Дополнительно выявлены ошибки классификации для класса 6, обусловленные, на наш взгляд, количеством обучающих данных. В целом модель демонстрирует высокую эффективность и пригодность для автоматической классификации изображений.

Class	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6
Class 1	19	0	0	0	0	0
Class 2	0	30	0	2	0	0
Class 3	0	0	6	0	0	0
Class 4	0	5	0	59	0	0
Class 5	1	0	0	0	10	0
Class 6	3	0	0	0	0	4
Prediction	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6

Рисунок 3. Матрица ошибок
Figure 3. Error matrix

Рисунок 4 представляет собой график зависимости точности классификации от номера эпохи обучения,

где кривые – асс – точность на обучающей выборке, test acc – точность на валидационной выборке.




Рисунок 4. Точность на каждую эпоху
 Figure 4. Accuracy for each epoch

Анализ динамики точности показал, что модель достигает высокой точности классификации уже на ранних этапах обучения. Обучающая точность быстро становится близка к 1,0, что свидетельствует о высокой способности модели к обучению. На тестовой выборке точность держится в пределах 0,91-0,93. Разница между точностью

на обучении и на тесте говорит о небольшом переобучении, но на итоговом качестве классификации это заметно не сказывается.

На графике потерь (рисунок 5) показана динамика кросс-энтропии в процессе обучения: Training Loss – на обучающей выборке, Test Loss – на валидационной.




Рисунок 5. Потеря точности на каждую эпоху
 Figure 5. Loss of accuracy for each epoch

По такому графику удобно отслеживать переобучение: если Test Loss начинает расти, а Training Loss продолжает снижаться – значит, модель начинает запоминать данные, а не обобщать. В нашем случае loss на обучении быстро падает почти до нуля. На тестовой выборке loss тоже снижается и затем выходит на плато – это говорит о том, что модель хорошо обобщает.

Незначительное увеличение test loss после 10-й эпохи указывает на умеренное переобучение, не оказывающее су-

щественного влияния на качество классификации. Оптимальная эффективность модели достигается на ранних этапах обучения.

Для каждого класса в отдельности отображается значение точности распознавания (Class Accuracy), рассчитанное на валидационной выборке, а также количество изображений данного класса, попавших в тестовый набор. Это позволяет оценить, для каких именно этапов органогенеза или типов почек модель работает недостаточно надежно.

CLASS	ACCURACY	# SAMPLES
Class 1	1.00	19
Class 2	0.94	32
Class 3	1.00	6
Class 4	0.92	64
Class 5	0.91	11
Class 6	0.57	7

Рисунок 6. Пример расчета точности на каждый класс
 Figure 6. Example of calculating accuracy for each class

Точность классификации была рассчитана для каждого класса как отношение числа правильно классифицированных изображений к общему числу изображений данного класса. Наибольшая точность (1,00) была получена для классов 1 и 3, тогда как для классов 2, 4 и 5 точность составила 0,91-0,94. Наиболее низкая точность наблюдалась для класса 6 (0,57), что связано, вероятно, с морфологической неоднородностью объектов. В целом модель демонстрирует высокую эффективность классификации большинства классов.

Результаты исследований и их обсуждение. Разработанная на платформе Teachable Machine модель машинного обучения продемонстрировала высокую эффективность при классификации микроскопических изображений почек яблони. Общая точность модели на тестовой выборке составила более 90%.

Для оценки качества распознавания по каждому из шести классов (вегетативные и генеративные почки на пяти этапах органогенеза) использовали стандартные метрики: точность (precision), полноту (recall) и F1-меру (таблица 3).

Таблица 3
Table 3

Метрики качества классификации типов и этапов развития почек яблони
Metrics for the classification of types and stages of apple bud development

Класс	Precision	Recall	F1-score
1	0,95	1,00	0,97
2	0,83	0,94	0,88
3	1,00	1,00	1,00
4	0,91	0,92	0,91
5	0,83	0,91	0,87

Лучшие показатели получены для классов 1 и 3 (F1 = 0,97 и 1,00). Для классов 2, 4 и 5 значения F1 находятся в интервале 0,87-0,91. Самое низкое значение (0,73) – у класса 6, главным образом из-за низкой полноты (recall = 0,57).

Разметка изображений выполнена авторами на основе микроскопического анализа. Модель обучалась на этих данных и автоматизирует распознавание этапов развития почек, не формируя самостоятельных морфологических описаний, а опираясь на визуальные признаки, выявленные в процессе обучения.

Микроскопический анализ исходных изображений позволил уточнить морфологические критерии разделения типов почек и этапов органогенеза, которые легли в основу обучающей выборки. Общая точность классификации (~0,91) и средняя F1-мера (~0,89) подтверждают, что выбранные критерии пригодны для автоматического распознавания.

Вегетативные почки уверенно распознаются (precision до 0,95-1,00, F1 до 0,97) благодаря характерной конической форме апекса, узкой апикальной меристеме и наличию преимущественно листовых зачатков без оси соцветия [22, 23].

У генеративных почек на первых этапах органогенеза точность несколько ниже (F1 ~0,87-0,88). Это объясняется ограниченным объёмом обучающей выборки и морфологической близостью переходных этапов, хотя в целом критерии (расширение апикальной меристемы, начало формирования осей соцветия) остаются чёткими.

На четвёртом этапе зачатки цветков визуализируются отчётливо, что даёт высокую точность (F1 до 1,00). Пятый этап (дифференциация чашелистиков, лепестков, тычинок) распознаётся стабильно (F1 ~0,91), несмотря на отдельные ошибки из-за сходства со смежными этапами. К концу пятого этапа формируется устойчивый морфологический паттерн, который модель распознаёт с F1 ~0,87. Высокая точность на поздних этапах объясняется их морфологической определённой и выраженностью признаков.

Для одного из классов позднего этапа наблюдается снижение полноты классификации (recall ~0,57), что указывает на недостаточное распознавание части объектов данного класса. Это связано, на наш взгляд, с повышенной вариативностью морфологических признаков.

Таким образом, разработанные морфологические критерии обеспечивают надёжную основу для автоматической классификации почек яблони, а использование методов машинного обучения, при условии репрезентативности обучающей выборки, позволяет достаточно точно определять этапы органогенеза.

Закключение. Традиционный подход к морфологической дифференциации почек основан на ручном анализе с использованием микроскопии, что требует значительного опыта исследователя и сопровождается существенными временными затратами. Компьютерное зрение для детекции и классификации микрофотографий почек яблони, оказалось вполне состоятельным инструментом для автоматического определения этапов морфогенеза. Точность модели высокая – на уровне 0,91, а F1-score – 0,89; т. е., машинный анализ даёт результат, близкий к экспертному.

Предложенное нами решение не отменяет необходимости первичной экспертной разметки при формировании набора данных, однако позволяет существенно ускорить и упростить дальнейшую обработку и классификацию больших массивов изображений. Поэтому разработанная система может рассматриваться как дополнение к классическим микроскопическим методам и эффективный инструмент поддержки принятия решений.

Для исследования был собран размеченный датасет из 1121 микроскопического снимка вегетативных и генеративных почек яблони на пяти последовательных этапах органогенеза. На этом массиве обучили модель на основе архитектуры сверточной нейронной сети MobileNet – она показала высокое качество классификации.

Лучше всего сеть распознаёт вегетативные почки и поздние стадии развития: здесь F1-score достигает 0,97-1,00. Это ожидаемо, поскольку морфологические признаки на этих этапах выражены наиболее чётко. Сложнее с ранними и переходными стадиями (I–II и III–IV этапы): F1-score держится в пределах 0,87-0,91, что связано с морфологической близостью соседних этапов. Для одного из классов, который был представлен в выборке хуже других, полнота (recall) составила около 0,57 – это говорит о том, что для дальнейшего улучшения нужно наращивать объём и репрезентативность обучающих данных.

В целом предложенный подход к цифровой детекции и классификации почек позволяет перейти к автоматизированному морфологическому анализу. Его применение даст

возможность вести масштабный мониторинг развития плодовых культур в садах, ускорить физиологические исследования, а также использовать результаты в системах точного

садоводства – для прогноза урожайности и корректировки агротехники.

Список источников

1. ФАОСТАТ [Электронный ресурс] : стат. база данных / Продовольственная и с.-х. организация ООН. 2025. URL: <https://www.fao.org/faostat/> (дата обращения: 30.03.2026).
2. Россия может выйти на полную самообеспеченность яблоками к 2028 году [Электронный ресурс] // ТАСС. 2026. URL: <https://tass.ru/ekonomika/24051039> (дата обращения: 26.03.2026).
3. О Доктрине продовольственной безопасности Российской Федерации : Указ Президента РФ от 21.01.2020 № 20 // Собрание законодательства РФ. 2020. № 4. Ст. 345.
4. Miranda J. C., Gené-Mola J., Zude-Sasse M. [et al.]. Fruit sizing using AI: a review of methods and challenges. *Postharvest Biology and Technology*, 2023, vol. 206, art. 112587. DOI: 10.1016/j.postharvbio.2023.112587.
5. Chen J., Wu J., Wang Z. [et al.]. Detecting ripe fruits under natural occlusion and illumination conditions. *Computers and Electronics in Agriculture*, 2021, vol. 190, art. 106450. DOI: 10.1016/j.compag.2021.106450.
6. Cheng H., Damerow L., Sun Y., Blanke M. Early yield prediction using image analysis of apple fruit and tree canopy features with neural networks. *Journal of Imaging*, 2017, vol. 3, no. 1, pp. 6. DOI: 10.3390/jimaging3010006.
7. Farjon G., Krikeb O., Hillel A. B., Alchanatis V. Detection and counting of flowers on apple trees for better chemical thinning decisions. *Precision Agriculture*, 2020, vol. 21, no. 3, pp. 503-521. DOI: 10.1007/s11119-019-09679-1.
8. Wang C., Lee W. S., Zou X. [et al.]. Detection and counting of immature green citrus fruit based on the Local Binary Patterns (LBP) feature using illumination normalized images. *Precision Agriculture*, 2019, vol. 19, no. 6, pp. 1062-1083. DOI: 10.1007/s11119-018-9574-5.
9. Wu G., Li B., Zhu Q., Huang M., Guo Y. Using color and 3D geometry features to segment fruit point cloud and improve fruit recognition accuracy. *Computers and Electronics in Agriculture*, 2020, vol. 174, art. 105475. DOI: 10.1016/j.compag.2020.105475.
10. Zhang C., Zou K., Pan Y. A method of apple image segmentation based on color texture fusion feature and machine learning. *Agronomy*, 2020, vol. 10, no. 7, pp. 972. DOI: 10.3390/agronomy10070972.
11. Bellocchio E., Costante G., Cascianelli S., Fravolini M.L., Valigi P. Combining domain adaptation and spatial consistency for unseen fruits counting: a quasi unsupervised approach. *IEEE Robotics and Automation Letters*, 2020, vol. 5, pp. 1079-1086. DOI: 10.1109/LRA.2020.2966398.
12. Chaivivatrakul S., Dailey M. N. Texture based fruit detection. *Precision Agriculture*, 2014, vol. 15, pp. 662-683. DOI: 10.1007/s11119-014-9361-x.
13. Casagrande E., Génard M., Lurol S. [et al.]. A process based model of nectarine quality development during pre and post harvest. *Postharvest Biology and Technology*, 2021, vol. 175, art. 111458. DOI: 10.1016/j.postharvbio.2020.111458.
14. Chen S. W., Shivakumar S. S., Dcunha S. [et al.]. Counting apples and oranges with deep learning: a data driven approach. *IEEE Robotics and Automation Letters*, 2017, vol. 2, pp. 781-788. DOI: 10.1109/LRA.2017.2651944.
15. Gao F., Fu L., Zhang X. [et al.]. Multi class fruit on plant detection for apple in SNAP system using Faster R CNN. *Computers and Electronics in Agriculture*, 2020, vol. 176, art. 105634. DOI: 10.1016/j.compag.2020.105634.
16. Majeed Y. [et al.]. Deep learning based segmentation for automated training of apple trees on trellis wires. *Computers and Electronics in Agriculture*, 2020. DOI: 10.1016/j.compag.2020.105277.
17. Pourdarbani R., Sabzi S., Kalantari D. [et al.]. Automatic non destructive video estimation of maturation levels in Fuji apple (*Malus pumila*) fruit in orchard based on colour (Vis) and spectral (NIR) data. *Biosystems Engineering*, 2020, vol. 195, pp. 136-151. DOI: 10.1016/j.biosystemseng.2020.04.015.
18. Adebayo S. E. [et al.]. Application and potential of backscattering imaging techniques in agricultural and food processing – a review. *Journal of Food Engineering*, 2016. DOI: 10.1016/j.jfoodeng.2015.08.006.
19. Bertone E. [et al.]. Prediction of the optimum harvest time of ‘Scarlet’ apples using DR UV–Vis and NIR spectroscopy. *Postharvest Biology and Technology*, 2012. DOI: 10.1016/j.postharvbio.2012.02.009.
20. Zhang W., Chen K., Wang J., Shi Y., Guo W. Easy domain adaptation method for filling the species gap in deep learning based fruit detection. *Horticulture Research*, 2021, vol. 8, pp. 119. DOI: 10.1038/s41438-021-00553-2.
21. Zhang W., Liu Y., Chen K. [et al.]. Lightweight fruit detection algorithm for edge computing applications. *Frontiers in Plant Science*, 2021, vol. 12, art. 740936. DOI: 10.3389/fpls.2021.740936.
22. Исаева И.С. Продуктивность яблони (процесс формирования) : монография. М. : Изд-во МГУ, 2009. 149 с.
23. Коломиец И.А. Биология развития генеративных органов и периодичность плодоношения яблони. Киев : Изд-во Укр. акад. с.-х. наук, 1961. 132 с.

References

1. FAOSTAT [Electronic resource] : statistical database / Food and Agriculture Organization of the United Nations. 2025. URL: <https://www.fao.org/faostat/> (accessed: 30.03.2026).
2. Russia may achieve full self-sufficiency in apples by 2028 [Electronic resource]. TASS. 2026. URL: <https://tass.ru/ekonomika/24051039> (accessed: 26.03.2026).
3. On the Food Security Doctrine of the Russian Federation : Decree of the President of the Russian Federation No. 20 of 21.01.2020. *Collection of Legislation of the Russian Federation*, 2020, no. 4, art. 345.
4. Miranda J. C., Gené-Mola J., Zude-Sasse M. [et al.]. Fruit sizing using AI: a review of methods and challenges. *Postharvest Biology and Technology*, 2023, vol. 206, art. 112587. DOI: 10.1016/j.postharvbio.2023.112587.
5. Chen J., Wu J., Wang Z. [et al.]. Detecting ripe fruits under natural occlusion and illumination conditions. *Computers and Electronics in Agriculture*, 2021, vol. 190, art. 106450. DOI: 10.1016/j.compag.2021.106450.

6. Cheng H., Damerow L., Sun Y., Blanke M. Early yield prediction using image analysis of apple fruit and tree canopy features with neural networks. *Journal of Imaging*, 2017, vol. 3, no. 1, pp. 6. DOI: 10.3390/jimaging3010006.
7. Farjon G., Krikeb O., Hillel A. B., Alchanatis V. Detection and counting of flowers on apple trees for better chemical thinning decisions. *Precision Agriculture*, 2020, vol. 21, no. 3, pp. 503-521. DOI: 10.1007/s11119-019-09679-1.
8. Wang C., Lee W. S., Zou X. [et al.]. Detection and counting of immature green citrus fruit based on the Local Binary Patterns (LBP) feature using illumination normalized images. *Precision Agriculture*, 2019, vol. 19, no. 6, pp. 1062-1083. DOI: 10.1007/s11119-018-9574-5.
9. Wu G., Li B., Zhu Q., Huang M., Guo Y. Using color and 3D geometry features to segment fruit point cloud and improve fruit recognition accuracy. *Computers and Electronics in Agriculture*, 2020, vol. 174, art. 105475. DOI: 10.1016/j.compag.2020.105475.
10. Zhang C., Zou K., Pan Y. A method of apple image segmentation based on color texture fusion feature and machine learning. *Agronomy*, 2020, vol. 10, no. 7, pp. 972. DOI: 10.3390/agronomy10070972.
11. Bellocchio E., Costante G., Cascianelli S., Fravolini M.L., Valigi P. Combining domain adaptation and spatial consistency for unseen fruits counting: a quasi unsupervised approach. *IEEE Robotics and Automation Letters*, 2020, vol. 5, pp. 1079-1086. DOI: 10.1109/LRA.2020.2966398.
12. Chaivivatrakul S., Dailey M.N. Texture based fruit detection. *Precision Agriculture*, 2014, vol. 15, pp. 662-683. DOI: 10.1007/s11119-014-9361-x.
13. Casagrande E., Génard M., Lurol S. [et al.]. A process based model of nectarine quality development during pre and post harvest. *Postharvest Biology and Technology*, 2021, vol. 175, art. 111458. DOI: 10.1016/j.postharvbio.2020.111458.
14. Chen S.W., Shivakumar S.S., Dcunha S. [et al.]. Counting apples and oranges with deep learning: a data driven approach. *IEEE Robotics and Automation Letters*, 2017, vol. 2, pp. 781-788. DOI: 10.1109/LRA.2017.2651944.
15. Gao F., Fu L., Zhang X. [et al.]. Multi class fruit on plant detection for apple in SNAP system using Faster R CNN. *Computers and Electronics in Agriculture*, 2020, vol. 176, art. 105634. DOI: 10.1016/j.compag.2020.105634.
16. Majeed Y. [et al.]. Deep learning based segmentation for automated training of apple trees on trellis wires. *Computers and Electronics in Agriculture*, 2020. DOI: 10.1016/j.compag.2020.105277.
17. Pourdarbani R., Sabzi S., Kalantari D. [et al.]. Automatic non destructive video estimation of maturation levels in Fuji apple (*Malus pumila*) fruit in orchard based on colour (Vis) and spectral (NIR) data. *Biosystems Engineering*, 2020, vol. 195, pp. 136-151. DOI: 10.1016/j.biosystemseng.2020.04.015.
18. Adebayo S. E. [et al.]. Application and potential of backscattering imaging techniques in agricultural and food processing – a review. *Journal of Food Engineering*, 2016. DOI: 10.1016/j.jfoodeng.2015.08.006.
19. Bertone E. [et al.]. Prediction of the optimum harvest time of ‘Scarlet’ apples using DR UV–Vis and NIR spectroscopy. *Postharvest Biology and Technology*, 2012. DOI: 10.1016/j.postharvbio.2012.02.009.
20. Zhang W., Chen K., Wang J., Shi Y., Guo W. Easy domain adaptation method for filling the species gap in deep learning based fruit detection. *Horticulture Research*, 2021, vol. 8, pp. 119. DOI: 10.1038/s41438-021-00553-2.
21. Zhang W., Liu Y., Chen K. [et al.]. Lightweight fruit detection algorithm for edge computing applications. *Frontiers in Plant Science*, 2021, vol. 12, art. 740936. DOI: 10.3389/fpls.2021.740936.
22. Isaeva I.S. Productivity of apple tree (formation process) : monograph. M. : Moscow State University Publishing House, 2009. 149 p.
23. Kolomiets I.A. Biology of the development of generative organs and periodicity of fruiting in apple trees. Kyiv : Publishing House of the Ukrainian Academy of Agricultural Sciences, 1961. 132 p.

Информация об авторах

И.В. Ариничева – доктор биологических наук, доцент, профессор кафедры высшей математики, СПИН-код 6169-1334;
Т.Н. Дорошенко – доктор сельскохозяйственных наук, профессор, заведующий кафедрой плодоводства, СПИН-код 9682-1495;
Ю.А. Онищенко – аспирант, СПИН-код 3772-4330.

Information about the authors

I.V. Arinicheva – Doctor of Biological Sciences, Associate Professor, Professor in the Department of Higher Mathematics, SPIN code 6169-1334;
T.N. Doroshenko – Doctor of Agricultural Sciences, Professor, Head of the Department of Fruit Growing, SPIN code 9682-1495;
Yu.A. Onishchenko – Postgraduate student, SPIN code 3772-4330.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Contribution of the Authors: all the authors have made an equivalent contribution to the preparation of the publication.

Авторы заявляют об отсутствии конфликта интересов.

The authors declare no conflicts of interests.

Статья поступила в редакцию 03.04.2026; одобрена после рецензирования 10.04.2026; принята к публикации 15.06.2026.
 The article was submitted 03.04.2026; approved after reviewing 10.04.2026; accepted for publication 15.06.2026.