

### Применение сверточных нейронных сетей для распознавания и подсчета цветковых почек яблони в промышленном садоводстве

**А. И. Кутырёв**, кандидат технических наук, ведущий научный сотрудник, заведующий лабораторией интеллектуальных цифровых систем мониторинга, диагностики и управления процессами в сельскохозяйственном производстве

ФГБНУ «Федеральный научный агроинженерный центр ВИМ»

109428, г. Москва, 1-й Институтский проезд, дом 5

✉ alexeykutyrev@gmail.com

**Резюме.** Существующие эмпирические методы оценки количества цветковых почек фруктовых деревьев трудоемки, субъективны и не обеспечивают необходимой точности для прогнозирования урожайности, определения сроков прореживания и нормирования нагрузки на дерево. В статье представлены результаты исследований по разработке автоматизированного инструмента для распознавания и подсчета цветковых почек яблони на основе сверточных нейронных сетей для цифровизации управления продуктивностью садовых насаждений. В качестве базовой архитектуры выбрана модель YOLO (You Only Look Once) версии 12 (YOLOv12) в пяти масштабах (nano, small, medium, large, x-large). Собран и размечен датасет из 1100 изображений цветковых почек яблони в трех масштабах: макросъемка, съемка сегментов ветвей и общие планы деревьев. Изображения были приведены к разрешению 640×640 пикселей и аугментированы (отражения, вращения, сдвиги, масштабирование, изменения яркости/контрастности, размытие). Обучение моделей (500 эпох, early stopping с patience=100, batch size=16) проводили на GPU NVIDIA RTX 2080 Ti с использованием фреймворков PyTorch/Ultralytics. Наивысшую среднюю точность детекции показала модель YOLOv12x (mAP@50=0,518). Разработан алгоритм визуализации, генерирующий аннотированные изображения с ограничивающими рамками (bounding boxes) и тепловые карты для анализа и интерпретации результатов распознавания. Разработанная система обеспечивает объективный цифровой мониторинг ключевого физиологического показателя – закладки цветковых почек. Использование системы (через мобильные приложения, обработку данных беспилотных летательных аппаратов (БЛА) или стационарные камеры) позволит прогнозировать урожайность, определять оптимальные сроки и интенсивность прореживания, оценивать эффективность агротехнических мероприятий, минимизировать риски периодичности плодоношения. Для промышленных садов в качестве оптимального решения выбрана модель YOLOv12s, показывающая сбалансированные показатели точности и скорости.

**Ключевые слова:** сверточные нейронные сети (CNN), детекция объектов, цветковые почки, яблоня, автоматизированный подсчет, прогнозирование урожайности, промышленное садоводство.

**Для цитирования:** Кутырев А. И. Применение сверточных нейронных сетей для распознавания и подсчета цветковых почек яблони в промышленном садоводстве // Вестник Ульяновской государственной сельскохозяйственной академии. 2026. № 2 (74). С. 188-197. doi:10.18286/1816-4501-2026-2-188-197

### Using convolutional neural networks to recognize and count apple flower buds in industrial horticulture

**A. I. Kutyrev**

FSBEI Federal Scientific Agroengineering Center VIM

109428, Moscow, 1st Institutsky Dr., Bld. 5

✉ alexeykutyrev@gmail.com

**Abstract.** Existing empirical methods for estimating the number of flower buds on fruit trees are labor-intensive, subjective, and do not provide the necessary accuracy for yield forecasting, determining thinning timing, and regulating tree load. This article presents results of the research on the development of an automated tool for recognizing and counting apple flower buds based on convolutional neural networks for the digitalization of orchard productivity management. The YOLO (You Only Look Once) model, version 12 (YOLOv12), was chosen as the base architecture, using five scales (nano, small, medium, large, and x-large). A dataset of 1,100 apple tree flower bud images was collected and annotated at three scales: macro, branch segment, and general tree views. The images were resized to a resolution of 640x640 pixels and augmented (reflections, rotations, translations, scaling, brightness/contrast changes, and blur). Training of models (500 epochs, early stopping with patience=100, batch size=16) was performed on an GPU NVIDIA RTX 2080 Ti using the PyTorch/Ultralytics frameworks. The YOLOv12x model demonstrated the highest average detection accuracy (mAP@50=0.518). A visualization algorithm was developed that generates annotated images with bounding boxes and heatmaps for analysis and interpretation of recognition results. The developed system provides objective digital monitoring of a key physiological parameter: flower bud initiation. Using the system (via mobile apps, processing data from unmanned aerial vehicles (UAVs), or stationary cameras) will allow to forecast yield, determine appropriate timing and intensity of thinning, assess the effectiveness

of agronomic measures, and minimize the risks of fruiting irregularities. For commercial orchards, the YOLOv12s model was selected as the appropriate solution, demonstrating a balance of accuracy and speed.

**Keywords:** convolutional neural networks (CNN), object detection, flower buds, apple tree, automated counting, yield forecasting, commercial horticulture

**For citation:** Kutryev A. I. Using convolutional neural networks to recognize and count apple flower buds in industrial horticulture // Vestnik of Ulyanovsk state agricultural academy. 2026.2 (74): 188-197 doi:10.18286/1816-4501-2026-2-188-197

**Работа выполнена при поддержке Минобрнауки России в рамках Государственного задания ФГБНУ «Федеральный научный агроинженерный центр ВИМ» (тема № FGUN-2025-0011).**

### Введение

Отрасль садоводства сталкивается с необходимостью повышения урожайности и качества плодов, что напрямую зависит от процессов закладки и формирования цветковых почек. Этот процесс является ключевым в жизненном цикле плодовых культур, определяя не только текущий урожай, но и продуктивность насаждений в последующие годы [1]. Процесс формирования цветковых почек находится в прямой зависимости от комплекса факторов, включая минеральное питание, водный режим, температурные условия и агротехнические мероприятия. Нарушение баланса этих факторов приводит к периодичности плодоношения, снижению качества плодов (размера, лежкости, ухудшению окраски) и ослаблению устойчивости деревьев к болезням и вредителям [2, 3, 4]. Например, высокие температуры (свыше 35 °C) в период образования цветковых почек снижают их жизнеспособность. Нарушение водного режима, как переувлажнение, так и засуха могут привести к преждевременному опадению завязей. Длительное переувлажнение особенно опасно для восприимчивых сортов. Кроме того, сильный рост деревьев, стимулируемый избыточным азотным питанием, способствует перераспределению питательных веществ, что негативно сказывается на закладке цветковых почек и качестве плодов [5, 6]. Чрезмерный рост не только замедляет закладку цветковых почек, но и повышает восприимчивость к болезням (ожогам, парше, мучнистой росе), снижает зимостойкость деревьев и качество плодов. Напротив, умеренный рост способствует улучшению качества цветковых почек, увеличению запаса питательных веществ, повышает устойчивость к неблагоприятным условиям [7].

В связи с этим актуальной задачей является разработка точных автоматизированных методов количественной оценки цветковых почек. Одним из перспективных направлений является применение компьютерного зрения и глубокого обучения для распознавания и анализа биологических объектов на различных стадиях их развития. В частности, использование сверточных нейронных сетей (CNN), таких как YOLO (You Only Look Once), открывает новые возможности для автоматического детектирования и классификации в режиме реального времени [8 - 11]. Разработка системы мониторинга плодовых почек на основе сверточной нейронной сети (CNN) позволяет решить несколько задач: автоматизировать количественную оценку цветковых почек, точно определять

оптимальные сроки прореживания, контролировать эффективность агротехнических мероприятий, прогнозировать потенциальную урожайность.

Исследование направлено на создание инструмента для автоматизированного подсчета цветковых почек яблони. Результаты работы имеют практическое значение для садоводства, так как позволят перейти от эмпирических методов управления продуктивностью насаждений к точным, основанным на данных цифрового мониторинга, которые обеспечат минимизацию субъективного человеческого фактора при анализе количества почек [12, 13]. Разработка системы мониторинга цветковых почек позволит не только прогнозировать урожайность, но и рассчитать научно обоснованную нагрузку на дерево (например, на основе нормы 6...7 плодов на 1 см<sup>2</sup> поперечного сечения штамба, в зависимости от сорта).

Цель исследования – разработка системы автоматизированного распознавания и количественной оценки цветковых почек яблони на основе сверточной нейронной сети для оптимизации управления продуктивностью садовых насаждений.

### Материалы и методы

Для детекции и подсчета цветковых почек выбрана архитектура YOLO (You Only Look Once). Выбор обусловлен оптимальным балансом модели между высокой скоростью работы (для применения в условиях промышленных садовых насаждений или обработки больших массивов данных) и достаточной точностью, особенно при детекции объектов небольшого размера на изображениях, какими являются цветковые почки. В сравнении с популярными архитектурами, такими как Faster R-CNN, SSD (Single Shot MultiBox Detector) или EfficientDet [14, 15, 16], современные версии YOLO показывают высокую точность при значительном преимуществе в быстродействии, а также обладают механизмами для работы с объектами разного масштаба. Выбранная модель YOLO12 включает следующие компоненты. Часть Backbone (CSPDarknet) извлекает иерархические признаки из изображения, состоит из сверточных слоев (Conv), слоев нормализации (BatchNorm), активаций SiLU и CSP-блоков (Cross Stage Partial Networks) для уменьшения вычислительных затрат. Часть Neck (PANet - Path Aggregation Network) объединяет признаки разного масштаба для распознавания объектов разных размеров. SPPF (Spatial Pyramid Pooling Fast) модуль добавляет контекст за счет пулинга (уменьшения размерности) на разных уровнях. Часть Head отвечает за окончательное предсказание ограничивающих

### 4.3.1. Технологии, машины и оборудование для агропромышленного комплекса (технические науки)

прямоугольников (bbox), уверенностей (confidence scores) и классов, «Anchor-free» подход (предсказывает центр объекта и его смещения) [17, 18].

Для оценки производительности различных вариантов YOLO12 в исследовании использовали модели пяти масштабов n (nano, nano), s (small, малый), m (medium, средний), l (large, большой), x (extra large, сверхбольшой), результаты сравнения точности которых представлены в таблице 1.

**Таблица 1. Результаты валидации моделей YOLO12 на датасете Objects in Context (COCO)**

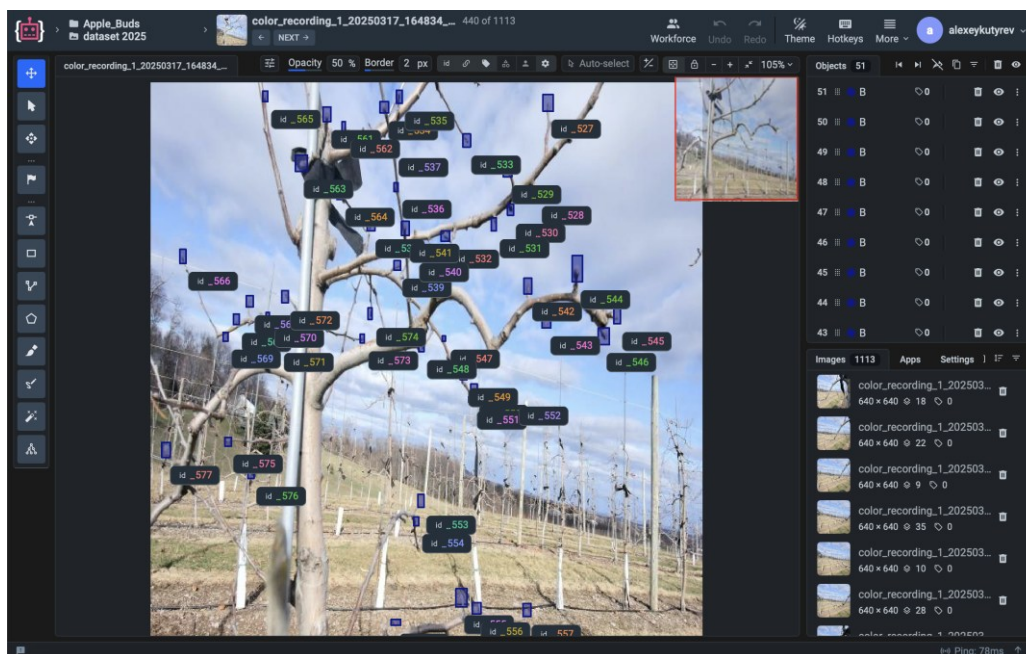
Модель	Метрика средней точности (mAP 0,50...0,95)	Количество параметров, млн. (mln)	Сравнение (mAP/Speed) на датасете COCO val2017
YOLO12x	55,2	59,1	+0,6 %/-4 % (по сравнению с YOLO11x)
YOLO12l	53,7	26,4	+0,4 %/-8 % (по сравнению с YOLO11l)
YOLO12m	52,5	20,2	+1 %/-3 % (по сравнению с YOLO11m)
YOLO12s	48,0	9,3	+0,1 %/+42 % (по сравнению с RT-DETRv2)
YOLO12n	40,6	2,6	+2,1 %/-9 % (по сравнению с YOLOv10n)

Все модели обрабатывают изображения с разрешением 640×640 пикселей. Точность детекции (mAP 0,50 и 0,95) возрастает пропорционально размеру модели: от 40,6 % у YOLO12n до 55,2 % у YOLO12x, при этом количество параметров увеличивается с

2,6 млн. до 59,1 млн. соответственно. Сравнение моделей с аналогами подтверждает их эффективность для задач реального времени.

Сбор изображений для обучения моделей YOLO12n-x проводили на стадии формирования цветковых почек при естественном освещении, в различные погодные условия (ясно, переменная облачность) и в разное время суток (утро, полдень). Использовали три масштаба съемки. Макросъемка (крупные планы - с расстояния 20...50 см) для детальной фиксации морфологии почек и их классификации (цветковая или ростовая). Съемка сегментов ветвей длиной 30...100 см велась с расстояния 0,5...1,5 м для фиксации расположения почек и их подсчета на ограниченном участке. Съемку общих планов деревьев или их значительных частей выполняли с расстояния 1,5...3 м) для оценки возможности масштабирования метода на уровень всего дерева и детекции почек небольшого размера. Для съемки использовали цифровые камеры GoPro HERO12 и iPhone 16 Pro Max для обеспечения разнообразия данных и дальнейшей оценки применимости моделей в условиях садовых насаждений.

Проведена ручная разметка (Ground Truth) изображений, выделены ограничивающие прямоугольники (bounding boxes, bbox) вокруг каждой видимой цветковой почки. Каждой цветковой почке присвоен класс («buds»). Для проведения разметки использовали платформу Supervisely (рис. 1).



**Рис. 1. Разметка изображений с использованием платформы Supervisely**

Всего собрано и размечено 1100 изображений и проведено разделение набора данных. Обучающий набор (Training Set) – 70 % изображений, использован для непосредственного обучения модели. Валидационный набор (Validation Set) – 15 % изображений, использован для подбора гиперпараметров (learning rate, batch size и т.д.), ранней остановки (early

stopping) и мониторинга процесса обучения (предотвращение переобучения). Тестовый набор (Test Set) – 15 % изображений, использован для финальной объективной оценки производительности обученной модели на новых данных, не использовавшихся в обучении или настройке. Изображения в тестовом

наборе отбирали случайным образом, но с сохранением пропорций по масштабу съемки.

Все изображения были приведены к единому разрешению 640x640 пикселей, совместимому с входным слоем CNN-архитектуры YOLO. Для увеличения размера и разнообразия обучающего набора, улучшения обобщающей способности модели и ее устойчивости к вариациям в реальных условиях была применена онлайн-аугментация (трансформации изображений генерировались случайным образом во время каждой эпохи обучения) к обучающему набору, включающая: пространственные трансформации - случайное горизонтальное отражение (Random Horizontal Flip), вращение (Random Rotation) в пределах  $\pm 15^\circ$ , сдвиг (Random Translation) по осям X и Y (до  $\pm 10\%$  от размера изображения), масштабирование (Random Zoom/Scale) в диапазоне [0,8...1,2]; цветовые и яркостные трансформации - случайное изменение яркости (Random Brightness)  $\pm 20\%$ , случайное изменение контрастности (Random Contrast)  $\pm 20\%$ , гауссово размытие (Gaussian Blur,  $\sigma = 0,5...1,5$ ).

Проводили качественный анализ ложноположительных (False Positives, FP) и ложноотрицательных (False Negatives, FN) предсказаний моделей на тестовых изображениях для выявления типичных ошибок моделей (например, цветковые почки в тени, или на сложном фоне неба) [19].

Метрику Precision (точность) – долю верно распознанных цветковых почек (True Positives, TP) среди всех обнаруженных моделью объектов использована для оценки способности минимизировать ложные срабатывания (False Positives, FP), вычисляли по формуле 1:

$$P = \frac{TP}{(TP+FP)}, \quad (1)$$

где P – Precision (точность, доля от 0 до 1); TP (True Positives) – количество верно распознанных цветковых почек, шт.; FP (False Positives) – количество ложных срабатываний модели, шт.

Метрику Recall (полнота) – доля верно распознанных почек (TP) среди всех существующих цветковых почек в данных использована для оценки способности моделей распознавать целевые объекты без пропусков (False Negatives, FN). Ее вычисляли по формуле 2:

$$R = \frac{TP}{(TP+FN)}, \quad (2)$$

где R – Recall (полнота, доля от 0 до 1); FN (False Negatives) – количество не распознанных моделью цветковых почек, шт.

Метрика mAP (mean Average Precision) – средняя точность по всем классам при пороговых значениях IoU = 0,5 и 0,95, использована для оценки общей производительности моделей детекции:

$$mAP@[0,5; 0,95] = \frac{1}{N} \sum_{i=1}^N \left( \frac{1}{10} \sum_{j=1}^{10} AP_i(IoU_j) \right), \quad (3)$$

где N – количество классов, шт.;  $AP_i$  – средняя точность для i-го класса,  $IoU_j$  – пороговое значение IoU, 0,5 и 0,95.

Проведено сравнение результатов автоматического подсчета с ручным подсчетом с использованием метрики средней абсолютной ошибки (Mean Absolute Percentage Error, MAPE), которую находили по формуле 4:

$$M = \frac{1}{K} \sum_{i=1}^K \left( \frac{|y_{true}^{(i)} - y_{pred}^{(i)}|}{y_{true}^{(i)}} \right) \cdot 100\% \quad (4)$$

где M – значение метрики MAPE, %; K – общее количество изображений (или зон подсчета), шт.; i – индекс изображения/зоны (i = 1, 2, ..., K);  $y_{true}^{(i)}$  – истинное количество почек на i-м изображении (ручной подсчет), шт.;  $y_{pred}^{(i)}$  – предсказанное количество почек на i-м изображении (автоматический подсчет), шт.; |·| – модуль разности (абсолютная ошибка).

Метрика MAPE, выраженная в процентах от истинного значения, позволила оценить относительную точность подсчета.

Исследование проводили на операционной системе Windows 10 с использованием языка Python 3.12. Основу глубокого обучения составили фреймворки PyTorch (в связке с высокоуровневым API Ultralytics для работы с моделями YOLO), TensorFlow 2.15.0, Keras 2.15.0 и JAX. Для задач компьютерного зрения, обработки данных, аугментации и оценки результатов использованы библиотеки OpenCV, NumPy, Pandas, Scikit-learn, Albumentations, Matplotlib/Seaborn и Pillow. Обучение моделей проводили на сервере с GPU NVIDIA RTX GeForce RTX 2080 Ti (11 Гб GDDR6) и 32 Гб DDR4 с использованием CUDA 12.2.

### Результаты

Начальная скорость обучения (Learning Rate, LR) установлена на уровне  $\sim 0,001$ . Размер пакета данных (Batch Size = 16) определен, исходя из доступной видеопамяти GPU. Использовано 500 эпох обучения, применена ранняя остановка (Early Stopping) с автоматической остановкой обучения модели, если точность на валидационном наборе перестает улучшаться в течение 100 эпох (patience = 100). Коэффициент весовой регуляризации (Weight Decay) составлял 0,0005 для предотвращения переобучения моделей.

Результаты экспериментов подтвердили эффективность архитектуры YOLOv12 для распознавания и подсчета цветковых почек яблони. Все пять моделей (nano, small, medium, large, x-large) достигли пика производительности на ранних эпохах обучения (49...134) и были остановлены механизмом ранней остановки (patience = 100). Для анализа полученных результатов и подсчета цветковых почек применяли порог уверенности (Confidence Threshold) 0,25-0,5, что позволяло исключать предсказания с низкой уверенностью. Наибольшую среднюю точность

### 4.3.1. Технологии, машины и оборудование для агропромышленного комплекса (технические науки)

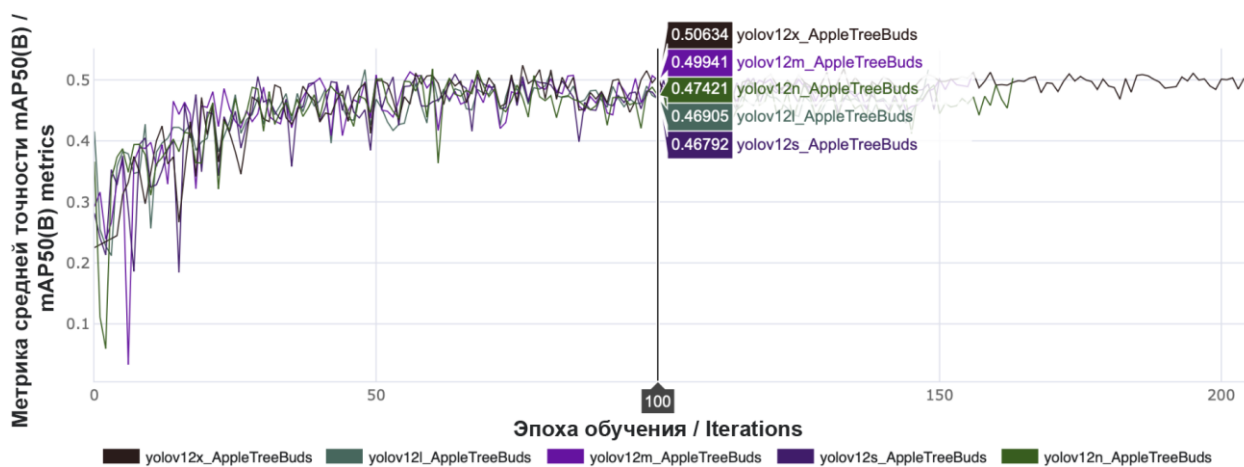
детекции показала модель с наибольшим количеством параметров YOLOv12x (mAP@50 = 0,518) (табл. 2).

**Таблица 2. Результаты тестирования работы моделей YOLO12 на тестовой выборке датасета**

Модель	YOLOv12x	YOLOv12l	YOLOv12m	YOLOv12s	YOLOv12n
Метрика средней точности mAP50(B)	0,518	0,516	0,512	0,503	0,502
Метрика средней точности mAP50-95(B)	0,215	0,215	0,213	0,219	0,211
Метрика Точности	0,591	0,615	0,627	0,590	0,607
Метрика Полноты	0,480	0,463	0,446	0,458	0,453

Модель YOLOv12s показала наивысшую устойчивость к вариациям масштаба (mAP@50-95 = 0,219).

Модель YOLOv12n обеспечила точность 95,4 % относительно ручного подсчета (MAPE = 4,6 %) при минимальных аппаратных требованиях и скорости обработки  $\geq 15,2$  FPS на GPU RTX 2080 Ti. Модели YOLOv12n и YOLOv12s показали оптимальный баланс между точностью подсчета (mAP@50 > 0,5) и скоростью работы, что подтверждает их применимость для автоматизированного мониторинга в условиях промышленных садовых насаждений. Модели среднего и малого размера (YOLOv12s, m) показали сопоставимую или даже лучшую точность (метрика Precision) и устойчивость к вариациям масштаба (mAP@50-95), что указывает на их эффективность для решения данной задачи. Кривые mAP50 и mAP50-95 подтвердили улучшение качества детекции с ростом количества эпох обучения (рис. 2).



**Рис. 2. Зависимость средней точности моделей от количества эпох обучения:**  
а – метрика mAP50, б – метрика mAP50-95

Основным направлением для улучшения качества распознавания остается повышение полноты обнаружения (метрика recall), значения которой для всех моделей находились в диапазоне 0,446...0,480.

Анализ кривых обучения показывает динамику изменения функции потерь (Loss) для моделей различных масштабов (YOLOv12n-x) в течение эпох

обучения. Модели достигли стабильной сходимости, причем варианты YOLOv12l,x показали более выраженное начальное снижение потерь. Модели (YOLOv12n, s) показали ускоренную стабилизацию потерь после ~50 эпох обучения, что подтверждает их эффективность при ограниченных вычислительных ресурсах (рис. 3).

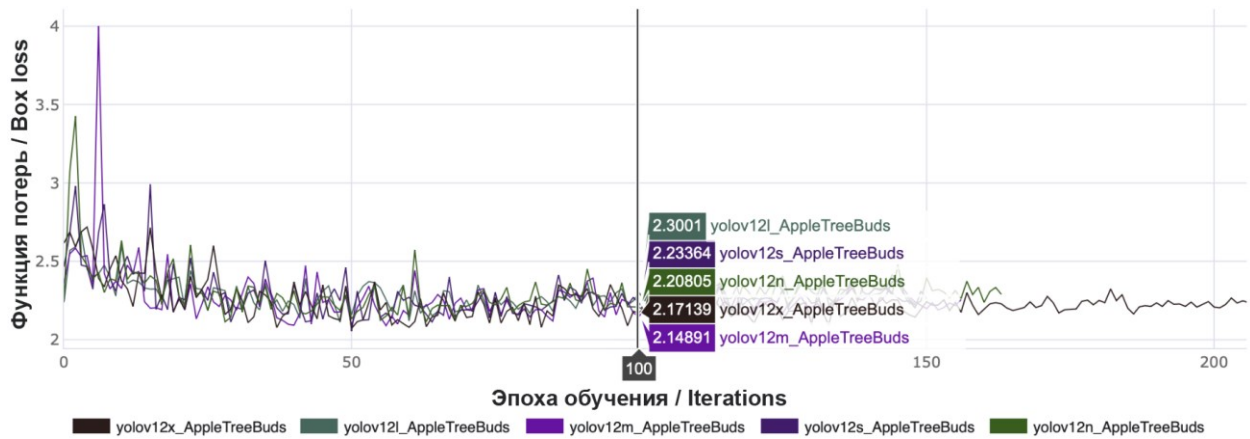



Рис. 3. Изменение функции потерь в зависимости от эпохи обучения



а



б

Рис. 4. Пример распознавания изображений с использованием обученной модели YOLO12x: а – аннотированное изображение с ограничивающими прямоугольниками (Bounding Boxes), б – тепловая карта уверенности модели (Confidence Heatmap)

В результате проведенных исследований разработан алгоритм, который генерирует два типа выходных изображений, содержащих специализированную цветовую шкалу для интерпретации данных. Пример работы алгоритма распознавания изображений с использованием обученной модели YOLO12x представлен на рисунке 4.

Цветовая шкала на изображениях отражает уверенность модели (confidence score) в распознавании каждой детектированной структуры цветковой почки. На аннотированном изображении ограничивающие рамки вокруг объектов окрашены градиентом от синего (низкая уверенность, 0...0,3) через зеленый и желтый (средняя уверенность, 0,3...0,7) к красному (высокая уверенность модели, 0,7...1). Это визуализирует степень уверенности модели в своем предсказании для каждого обнаруженного объекта: холодные тона сигнализируют о случаях, где модель менее уверена (например, цветковые почки в тени, на сложном фоне), а теплые тона указывают на объекты, которые модель с высокой степенью уверенности классифицировала как цветковые почки. На тепловой карте вокруг центра каждой распознанной почки генерируется гауссово пятно (размытая окружность). Интенсивность цвета этого пятна пропорциональна уверенности модели в распознавании цветковой почки. Параллельная генерация двух типов визуализации обеспечивает комплексный анализ: аннотированное изображение оптимизировано для точного подсчета, а тепловая карта предназначена для диагностики системных ошибок модели и оценки влияния условий съемки (освещение, ракурс) на достоверность прогноза. Оба типа изображений дополнены панелью статистики в правом верхнем углу, которая содержит итоговое количество распознанных почек на изображении и время обработки изображения моделью (в секундах), что облегчает интерпретацию результатов как в полевых условиях, так и при анализе системных ошибок модели и оценке влияния условий съемки (освещение, ракурс).

#### Обсуждение

Анализ ложноположительных (FP) и ложноотрицательных (FN) срабатываний моделей на тестовой выборке выявил характерные ошибки, ограничивающие точность моделей. Наиболее сложными для детекции оказались цветковые почки в условиях неравномерного освещения, тени (особенно при боковом освещении), а также области с сильной засветкой (блики на молодых побегах), что часто приводило к пропускам (FN). Значительное количество FN также наблюдали для цветковых почек небольшого размера на изображениях общего плана деревьев (расстояние съемки > 2 м), где почки занимали менее 10×10 пикселей, и их признаки сливались с шумом или текстурой коры. Сложный фон, особенно небо (яркое или перекрытое тонкими ветвями) и хаотично расположенные ветки, также являлись источником FP, когда модель ошибочно детектировала эти объекты как цветковые почки. Выявленные

закономерности указывают на необходимость не только совершенствования архитектуры сети, но и учёта физиологических параметров развития почек.

Результаты работ [3] и [4] подтверждают важность мониторинга таких параметров, как температурный режим, водный стресс и др., однако не предлагают инструмента для полевой количественной оценки почек. Представленная работа позволяет связать данные биологических измерений с цифровыми показателями закладки цветковых почек, получаемыми автоматизированным способом.

Если спектроскопия даёт обобщенные данные, не различая отдельные почки в кластере [5], то разработанная система обеспечивает индивидуальную детекцию каждой почки с визуализацией её местоположения. Кроме того, точность классификации [5] (76...82 %) уступает точности подсчёта разработанной системы.

Исследования [6, 7] посвящены аэросъёмке и классификации стадий развития цветковых почек с использованием моделей YOLOv8, YOLOv7 и YOLOv4, тогда как в настоящей работе система основана на трёх масштабах съёмки (макро, сегменты ветвей, общие планы деревьев) и решает задачу автоматизированного подсчёта, а не только детекции или классификации, при этом применение YOLOv12 обеспечивает высокую точность детекции мелких объектов за счёт улучшенной архитектуры (CSPDarknet, PANet, SPPF).

Дополнительным преимуществом разработанной системы являются тепловые карты уверенности для интерпретации ошибок модели, что не предусмотрено в работах [6, 7, 8, 10], а также [11]. Метод GAN [9] требует генерации синтетических данных для балансировки классов, тогда как разработанная система работает непосредственно на реальных изображениях и решает задачу подсчёта без дополнительных этапов обработки.

Методы на основе архитектур Faster R-CNN [14] и SSD [15], а также генеративные подходы [16] показывают более низкую эффективность для задачи автоматизированного подсчёта. Предложенная система обеспечивает не только высокую точность детекции, но и автоматизированный подсчёт цветковых почек с ошибкой по метрике MAPE ~5 %.

Разработанная система может быть интегрирована в качестве сенсорного модуля в общую архитектуру управления агротехнологиями, предложенную в исследованиях [12, 13]. Это позволит дополнить существующие подсистемы объективными цифровыми данными о закладке цветковых почек, что повысит точность прогнозирования урожайности и оптимизации нормировки нагрузки на деревья в рамках единой автоматизированной системы.

Практическая реализация разработанной системы может быть выполнена в нескольких вариантах в зависимости от задач хозяйства. Во-первых, система может быть реализована через мобильное приложение, в этом случае агроном использует

планшет с приложением со встроенной моделью, такой как YOLOv12n или YOLOv12s, для фотографирования деревьев яблони и получает оценку количества цветковых почек в режиме реального времени. Во-вторых, возможна обработка данных, собранных с помощью беспилотных летательных аппаратов (БЛА), которые выполняют аэросъемку садовых насаждений, а полученные изображения затем анализируются облачной платформой, использующей модели YOLOv12l или YOLOv12x. Это позволяет создавать детальные карты пространственного распределения и плотности цветковых почек по всему саду. В-третьих, система может быть развернута с использованием стационарных камер, установленных на опорах или деревьях, для постоянного мониторинга состояния и динамики закладки почек на конкретных, выбранных в качестве контрольных, деревьях в течение всего сезона.

Научная значимость представленного исследования заключается в переходе от качественного визуального и инструментального анализа состояния почек к полностью автоматизированному количественному учёту. Впервые выполнено сравнение пяти масштабов архитектуры YOLOv12 применительно к задаче детекции цветковых почек яблони на разнородных изображениях. Разработанные тепловые карты уверенности позволяют интерпретировать результаты работы модели и диагностировать системные ошибки. Разработанная система обеспечивает основу для прогнозирования урожайности, оптимизации прореживания и нормировки нагрузки на дерево, а также для оценки эффективности агротехнических мероприятий.

#### **Заключение**

Разработанная система на базе свёрточных нейронных сетей, в частности моделей YOLOv12n и YOLOv12s, обеспечивает решение поставленной задачи создания инструмента для автоматизированного распознавания и количественной оценки цветковых почек яблони. Сравнение метрик по всем моделям подтвердило, что переход к более крупным моделям (s, m, l, x) даёт незначительное улучшение точности подсчёта (снижение метрики MAPE на 0,5...1,5%), которое не всегда оправдывает резкий рост вычислительных требований и снижение скорости работы, особенно в режиме реального времени на менее мощном оборудовании (например, на мобильных платформах типа NVIDIA Jetson или на центральных процессорах CPU).

Оптимальным решением для условий промышленных садов, требующих баланса точности и скорости, является модель YOLOv12s, показывающая лучшую устойчивость к вариациям масштаба ( $mAP@50-95 = 0,219$ ) и приемлемую для многих задач точность подсчёта ( $MAPE \sim 5\%$ ). При ограничениях по вычислительным ресурсам (мобильные устройства) предпочтительна модель YOLOv12n, обеспечивающая достаточную точность при высокой скорости обработки кадров ( $\geq 15,2$  FPS).

Система обеспечивает объективную количественную оценку закладки цветковых почек - ключевого физиологического показателя, определяющего будущий урожай, и позволяет перейти от субъективных эмпирических оценок к точным, основанным на цифровых данных. Автоматизация подсчета позволяет точно определить оптимальные сроки и интенсивность прореживания (нормировки) цветков или завязей на основе прогнозируемой нагрузки, минимизируя риски периодичности плодоношения. Мониторинг динамики закладки почек дает возможность оценить эффективность агротехнических мероприятий (орошение, подкормка, обрезка и др.) в режиме реального времени.

#### **Литература**

1. Mild Water Stress Makes Apple Buds More Likely to Flower and More Responsive to Artificial Forcing - Impacts of an Unusually Warm and Dry Summer in Germany / E. Fernandez, E. Luedeling, D. Behrend, et al. // *Agronomy*. 2020. Vol. 10. No. 2. P. 274. doi:10.3390/agronomy10020274
2. Apple, Peach, and Pear Flower Detection Using Semantic Segmentation Network and Shape Constraint Level Set / K. Sun, X. Wang, S. Liu, et al. // *Computers and Electronics in Agriculture*. 2021. No. 185. P. 106150. doi:10.1016/j.compag.2021.106150
3. Bilavcik A., Zamecnik J., Faltus M. Cryotolerance of apple tree bud is independent of endodormancy // *Frontiers in Plant Science*. 2015. No. 6. P. 695. doi:10.3389/fpls.2015.00695
4. The Identification of Small RNAs Differentially Expressed in Apple Buds Reveals a Potential Role of the Mir159-MYB Regulatory Module during Dormancy / J. Garighan, E. Dvorak, J. Estevan, et al. // *Plants*. 2021. Vol. 10. No.12. P. 2665. doi:10.3390/plants10122665
5. Botirov A., Arakawa O., Zhang S. Forecasting Young Apple Tree Bud Status with a Visible/Near-Infrared Spectrometer // *J Crop Tech Agri Sci*. 2021. Vol. 3. No. 1. P. 001.
6. Yuan W. AriAplBud: An Aerial Multi-Growth Stage Apple Flower Bud Dataset for Agricultural Object Detection Benchmarking // *Data*. 2024. Vol. 9. No. 2. P. 36. doi:10.3390/data9020036
7. Yuan W. Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification // *AgriEngineering*. 2023. Vol. 5. No. 1. P. 413-424. doi:10.3390/agriengineering5010027
8. Кутырёв А. И. Распознавание и классификация болезней листьев яблони на основе анализа их изображений моделями сверточных нейронных сетей (CNN) // *Вестник Ульяновской государственной сельскохозяйственной академии*. 2023. Т. 3. № 63. С. 215-223. doi:10.18286/1816-4501-2023-3-215-223
9. Yuan W., Li P. Lightweight GAN-Assisted Class Imbalance Mitigation for Apple Flower Bud Detection // *Big Data and Cognitive Computing*. 2025. Vol. 9. No. 2. P. 28. doi:10.3390/bdcc9020028

10. Fang W., Chen W. TBF-YOLOv8n: A Lightweight Tea Bud Detection Model Based on YOLOv8n Improvements // *Sensors*. 2025. Vol. 25. No. 2. P. 547. doi:10.3390/s25020547

11. Кутырёв А. И., Смирнов И. Г., Андриянов Н. А. Сравнительный анализ моделей нейронных сетей для распознавания плодов яблони на кроне дерева // *Садоводство и виноградарство*. 2023. № 5. С. 56-63. doi:10.31676/0235-2591-2023-5-56-63

12. Разработка системы автоматизированного управления агротехнологиями в садоводстве / Д. О. Хорт, А. И. Кутырёв, И. Г. Смирнов и др. // *Сельскохозяйственные машины и технологии*. 2021. Т. 15. № 2. С. 61-68. doi:10.22314/2073-7599-2021-15-2-61-68

13. Повышение эффективности системы управления растениеводством на основе цифровых технологий / Г. С. Клычова, А. Р. Закирова, А. Р. Валиев и др. // *Вестник Казанского государственного аграрного университета*. 2021. Т. 16. № 3(63). С. 121-127. doi:10.12737/2073-0462-2021-121-127

14. Gong X., Zhang S. A High-Precision Detection Method of Apple Leaf Diseases Using Improved Faster R-CNN // *Agriculture*. 2023. Vol. 13. No. 2. P. 240. doi:10.3390/agriculture13020240.

15. DBA\_SSD: A Novel End-to-End Object Detection Algorithm Applied to Plant Disease Detection / J. Wang, L. Yu, J. Yang, et al. // *Information*. 2021. Vol. 12. No. 11. P. 474. doi: 10.3390/info12110474

16. Using Generative Module and Pruning Inference for the Fast and Accurate Detection of Apple Flower in Natural Environments / Y. Zhang, S. He, S. Wa, et al. // *Information*. 2021. Vol. 12. No. 12. P. 495. doi:10.3390/info12120495

17. Terven J., Córdova-Esparza D-M., Romero-González J-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // *Machine Learning and Knowledge Extraction*. 2023. Vol. 5. No. 4. P. 1680-1716. doi:10.3390/make5040083

18. Diwan T., Anirudh G., Tembhurne J. V. Object detection using YOLO: Challenges, architectural successors, datasets and applications // *Multimed. Tools Appl.* 2023. No. 82. P. 9243-9275

19. Maxwell A. E., Warner T. A., Guillén L. A. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies - Part 1: Literature Review // *Remote Sensing*. 2021. Vol. 13. No. 13. P. 2450. doi:10.3390/rs13132450

#### References

1. Mild Water Stress Makes Apple Buds More Likely to Flower and More Responsive to Artificial Forcing - Impacts of an Unusually Warm and Dry Summer in Germany / E. Fernandez, E. Luedeling, D. Behrend, et al. // *Agronomy*. 2020. Vol. 10. No. 2. P. 274. doi:10.3390/agronomy10020274.

2. Apple, Peach, and Pear Flower Detection Using Semantic Segmentation Network and Shape Constraint Level Set / K. Sun, X. Wang, S. Liu, et al. // *Computers and*

*Electronics in Agriculture*. 2021. No. 185. P. 106150. doi:10.1016/j.compag.2021.106150.

3. Bilavcik A., Zamecnik J., Faltus M. Cryotolerance of apple tree bud is independent of endodormancy // *Frontiers in Plant Science*. 2015. No. 6. P. 695. doi:10.3389/fpls.2015.00695.

4. The Identification of Small RNAs Differentially Expressed in Apple Buds Reveals a Potential Role of the Mir159-MYB Regulatory Module during Dormancy / J. Garighan, E. Dvorak, J. Estevan, et al. // *Plants*. 2021. Vol. 10. No.12. P. 2665. doi:10.3390/plants10122665.

5. Botirov A., Arakawa O., Zhang S. Forecasting Young Apple Tree Bud Status with a Visible/Near-Infrared Spectrometer // *J Crop Tech Agri Sci*. 2021. Vol. 3.No. 1. P.001.

6. Yuan W. AriAplBud: An Aerial Multi-Growth Stage Apple Flower Bud Dataset for Agricultural Object Detection Benchmarking // *Data*. 2024. Vol. 9. No. 2. P. 36. doi:10.3390/data9020036

7. Yuan W. Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification // *AgriEngineering*. 2023. Vol. 5. No. 1. P. 413-424. doi: 10.3390/agriengineering5010027

8. Kutyrev A.I. Recognition and classification of apple leaf diseases based on image analysis by convolutional neural network (CNN) Models // *Vestnik of Ulyanovsk State Agricultural Academy*. 2023. Vol. 3. No. 63. P. 215-223. doi:10.18286/1816-4501-2023-3-215-223

9. Yuan W., Li P. Lightweight GAN-Assisted Class Imbalance Mitigation for Apple Flower Bud Detection // *Big Data and Cognitive Computing*. 2025. Vol. 9.No. 2. P. 28. doi:10.3390/bdcc9020028

10. Fang W., Chen W. TBF-YOLOv8n: A Lightweight Tea Bud Detection Model Based on YOLOv8n Improvements // *Sensors*. 2025. Vol. 25. No. 2. P. 547. doi:10.3390/s25020547

11. Kutyrev A. I., Smirnov I. G., Andryanov N. A. Comparative analysis of neural network models for recognizing apple fruits on a tree crown // *Horticulture and Viticulture*. 2023. No. 5. P. 56-63. doi:10.31676/0235-2591-2023-5-56-63

12. Development of an automated control system for agricultural technologies in horticulture / D. O. Khort, A. I. Kutyrev, I. G. Smirnov et al. // *S Agricultural machinery and technologies*. 2021. Vol. 15. No. 2. P. 61-68. doi:10.22314/2073-7599-2021-15-2-61-68

13. Improvement of the efficiency of crop management systems based on digital technologies / G. S. Klychova, A. R. Zakirova, A. R. Valiev, et al. // *Vestnik of Kazan State Agrarian University*. 2021. Vol. 16. No. 3(63). P. 121-127. doi:10.12737/2073-0462-2021-121-127

14. Gong X., Zhang S. A High-Precision Detection Method of Apple Leaf Diseases Using Improved Faster R-CNN // *Agriculture*. 2023. Vol. 13.No. 2. P. 240. doi:10.3390/agriculture13020240

15. DBA\_SSD: A Novel End-to-End Object Detection Algorithm Applied to Plant Disease Detection / J. Wang,

L. Yu, J. Yang, et al. //Information. 2021. Vol. 12.No. 11. P. 474. doi: 10.3390/info12110474

16. Using Generative Module and Pruning Inference for the Fast and Accurate Detection of Apple Flower in Natural Environments / Y. Zhang, S. He, S. Wa, et al. //Information. 2021. Vol. 12.No. 12. P. 495. doi:10.3390/info12120495

17. Terven J., Córdova-Esparza D-M., Romero-González J-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // Machine Learning and Knowledge

Extraction. 2023. Vol. 5.No. 4. P. 1680-1716. doi:10.3390/make5040083

18. Diwan T., Anirudh G., Temburne J. V. Object detection using YOLO: Challenges, architectural successors, datasets and applications // Multimed. Tools Appl. 2023. No. 82. P. 9243-9275

19. Maxwell A. E., Warner T. A., Guillén L. A. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies - Part 1: References Review // Remote Sensing. 2021. Vol. 13.No. 13. P. 2450.