

## Оригинальная статья / Original article

УДК 519.85

<https://doi.org/10.21869/2223-1560-2025-29-4-187-203>

## Алгоритм автоматического подсчета рыб на изображении и слежения за их движением на основе нейронной модели YOLOv9t

В.Н. Ле<sup>1</sup> ✉

<sup>1</sup> Санкт-Петербургский Федеральный исследовательский центр Российской академии наук,  
14-я линия В.О., д. 39, Санкт-Петербург 199178, Российская Федерация

✉ e-mail: lenghia18071999@gmail.com

### Резюме

**Цель исследования.** Традиционные методы, основанные на визуальном наблюдении и ручном подсчете, не только обладают очевидными ограничениями с точки зрения затрат времени и людских ресурсов, но и дают недостаточно точные результаты из-за субъективного человеческого фактора в процессе работы. Эти погрешности, даже незначительные, могут привести к ошибочным управленческим решениям, что негативно сказывается на эффективности производства в аквакультуре.

**Методы.** С целью устранения указанных недостатков в данной статье представлено автоматизированное решение, использующее нейронную модель YOLOv9t для задачи обнаружения и подсчета рыбы на изображениях, выполненных под водой. Благодаря оптимизированной архитектуре нейронной модели YOLOv9t, включающей всего 2 млн параметров, продемонстрированы высокие результаты определения рыб на изображениях из набора данных DeepFish: Точность - 0.928, Полнота - 0.91, mAP50 - 0.961 и mAP50-95 - 0.584. Метод Non-Maximum Suppression использован для устранения дублирующихся случаев обнаружения рыб на одной области, а применение алгоритма DeepSORT позволило непрерывно отслеживать каждую особь на последовательности кадров в видеозаписи с помощью уникальных идентификаторов.

**Результаты** исследования подтвердили, что нейронная модель YOLOv9t пригодна для создания автоматизированных систем видеоаналитики в рыбоводстве для мониторинга за поведением рыб и управления активационными устройствами. Это позволяет перевести ключевые процессы контроля на полностью автоматизированную основу, оптимизируя использование ресурсов. Предложенная архитектура обеспечила высокую точность и надежность в различных условиях среды - от прозрачной до мутной воды, открывая перспективы для применения на производстве в реальных условиях эксплуатации.

**Заключение.** Такая стабильность работы делает систему готовой для внедрения в промышленных масштабах с целью повышения эффективности управления хозяйством.

**Ключевые слова:** YOLO; искусственный интеллект; аквакультура; машинное обучение; нейронная сеть.

**Конфликт интересов:** Автор декларирует отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

**Для цитирования:** Ле В.Н. Алгоритм автоматического подсчета рыб на изображении и слежения за их движением на основе нейронной модели YOLOv9t // Известия Юго-Западного государственного университета. 2025; 29(4): 187-203. <https://doi.org/10.21869/2223-1560-2025-29-4-187-203>.

Поступила в редакцию 11.09.2025

Подписана в печать 27.10.2025

Опубликована 22.12.2025

© Ле В.Н., 2025

# Algorithm for automatic counting of fish in an image and tracking their movement based on the YOLOv9t neural model

Le Van Nghia<sup>1</sup> ✉

<sup>1</sup> St. Petersburg Federal Research Center of the Russian Academy of Sciences  
14th Line V.O., 39, St. Petersburg 199178, Russian Federation

✉ e-mail: lenghia18071999@gmail.com

## Abstract

**Purpose of research.** Traditional methods based on visual observation and manual counting not only have obvious limitations in terms of time and human resource costs but also yield insufficiently accurate results due to the subjective human factor involved in the process. These inaccuracies, even minor ones, can lead to erroneous management decisions, which negatively impact production efficiency in aquaculture.

**Methods.** To eliminate these shortcomings, this paper presents an automated solution that utilizes the YOLOv9t neural network model for the task of detecting and counting fish in underwater images. Thanks to the optimized architecture of the YOLOv9t neural model, which contains only 2 million parameters, it demonstrated high performance in identifying fish in images from the DeepFish dataset, with the following evaluation metrics: Precision - 0.928, Recall - 0.91, mAP50 - 0.961, and mAP50-95 - 0.584. The Non-Maximum Suppression method was used to eliminate duplicate detections of fish in the same area, while the application of the DeepSORT algorithm enabled the continuous tracking of each individual across video frame sequences by assigning unique identifiers.

**Results.** The research results confirmed that the YOLOv9t neural model is suitable for creating automated video analytics systems in aquaculture for monitoring fish behavior and managing activation devices. This enables the transition of key control processes to a fully automated basis, thereby optimizing resource utilization. The proposed architecture provided high accuracy and reliability across various environmental conditions—from clear to murky water—opening prospects for application in real-world production environments.

**Conclusion.** This operational stability makes the system ready for industrial-scale implementation with the aim of enhancing farm management efficiency.

**Keywords:** YOLO, artificial intelligence, aquaculture, machine learning, neural network.

**Conflict of interest.** The Author declare the absence of obvious and potential conflicts of interest related to the publication of this article.

**For citation:** Le V.N. Algorithm for automatic counting of fish in an image and tracking their movement based on the YOLOv9t neural model. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2025; 29(4): 187-203 (In Russ.). <https://doi.org/10.21869/2223-1560-2025-29-4-187-203>.

Received 11.09.2025

Accepted 27.10.2025

Published 22.12.2025

\*\*\*

## Введение

Одной из самых серьезных проблем, с которыми сталкиваются владельцы рыбных хозяйств, является точное определение плотности рыбы, отслеживание уровня потерь и прогнозирование

объема вылова. Традиционные методы, такие как ручной подсчет, не только требуют значительных затрат времени и рабочей силы, но и подвержены большим погрешностям, вызывают стресс у рыб [1], а главное – приводят к неточ-

ным управленческим решениям в вопросах кормления, профилактики заболеваний и планирования сбора урожая.

Прогресс в области робототехники [2-3], Интернета вещей (IoT) [4], искусственного интеллекта (AI) [5-7], и особенно компьютерного зрения [8-10], открывает новую эпоху индустриальной аквакультуры [11-12]. В этом контексте глубокие нейронные сети позволяют реализовать автоматический, непрерывный и высокоточный мониторинг поведения рыб и отдельных особей. Среди них особенно выделяется семейство нейронных моделей YOLO (You Only Look Once) – архитектура для обнаружения объектов в реальном времени, отличающаяся высокой скоростью и точностью [13]. Способность модели обрабатывать видеопотоки, поступающие напрямую с камер, установленных в рыбноводных садках, с целью распознавания и подсчета каждой особи в реальном времени делает модель YOLO идеальным решением, способным революционизировать процесс управления рыбными фермами [14-15]. Однако успешное внедрение модели YOLO в условиях промышленного рыбоводства требует специализированного процесса ее обучения и подготовки представительного корпуса данных. Кроме того, необходимо адаптировать ее к специфическим особенностям среды, таким как: высокая мутность воды, высокая плотность рыбы, вызывающая взаимное перекрытие особей, разнообразие размеров и видов рыб в одной системе, а также из-

менения освещенности в течение суток [16]. Это, в свою очередь, требует качественного набора изображений, тщательно размеченного на основе данных реальных ферм, а также применения методов аугментации данных и тонкой настройки модели.

Исходя из указанных практических требований, данное исследование было направлено на разработку и обучение оптимизированной модели YOLO, адаптированной для условий промышленного рыбоводства при подсчете рыбы. В статье подробно рассматриваются алгоритм обучения модели и результаты экспериментов, включая показатели точности и полноты обнаружения. В разделе 1 представлена методика и алгоритм обучения модели YOLO, а также алгоритм подсчета рыбы. В разделе 2 описаны эксперименты и оценка результатов на модели YOLOv9t.

## Материалы и методы

YOLO – это модель глубокой нейронной сети, разработанная для решения задачи распознавания объектов на изображениях и в видео. Особенностью YOLO по сравнению с другими моделями является способность быстро и точно определять объекты, одновременно предоставляя информацию об их расположении и типе на изображении.

YOLO использует глубокую нейронную сеть, состоящую из множества слоев, включая сверточные слои (CNN) [17], которые извлекают признаки из изображения.

Модель делит входное изображение на небольшие сетки (grid cells), каждая из которых предсказывает параметры, связанные с возможным присутствием объекта в этой области, включая:

- Положение объекта (координаты углов ограничивающего прямоугольника - bounding box).
- Вероятность наличия объекта (связанную с вероятностью присутствия, например, рыбы).
- Класс объекта (например, рыба или другие животные).

Благодаря этому YOLO может распознавать и классифицировать несколько объектов на одном изображении или в видео без необходимости выполнять множество отдельных проходов, как это делают традиционные модели.

Для повышения точности и скорости были разработаны усовершенствованные версии YOLO, последняя из которых - YOLOv12 [18]. Каждая версия содержит значительные улучшения в точности распознавания объектов и скорости обработки, особенно в условиях видеоанализа.

#### Алгоритм обучения модели YOLO для подсчета рыб

Процесс обучения модели нейронной модели YOLO, предназначенной для решения задач обнаружения и подсчета рыб на изображениях или видеопоследовательностях, представлен на рис. 1. На первом этапе проводится сбор изображений, после чего созданный корпус разделяется на три незави-

симые части, используемые для различных этапов разработки модели глубокого обучения. В частности, 80 % изображений формируют обучающую выборку, предназначенную для оптимизации весовых коэффициентов нейронной сети; 10 % данных составляют валидационную выборку, служащую для контроля и оценки производительности модели в процессе обучения, а также для настройки гиперпараметров и выявления признаков переобучения; оставшиеся 10 % образуют тестовую выборку, применяемую для оценки способности модели к обобщению на новых, ранее не встречавшихся данных.

Все изображения после аннотирования масштабируются до стандартизированного разрешения  $640 \times 640$  пикселей. Данный размер является оптимальным и широко используется в современных архитектурах сверточных нейронных сетей, применяемых для решения задач обнаружения объектов (object detection), включая модель YOLO. Выбор такого разрешения обеспечивает сохранение достаточного количества визуальных признаков при умеренных вычислительных затратах, что особенно важно при обучении на графических процессорах со средней производительностью.

Перед подачей в сеть все изображения проходят нормализацию интенсивностей пикселей в диапазоне  $[-1, 1]$  посредством линейного преобразования исходных значений, находящихся в диапазоне  $[0, 255]$ . Этот этап способствует стабилизации процесса распространения

сигналов по слоям сети, ускоряет сходимость оптимизационного процесса и снижает дисперсию входных данных между мини-пакетами изображений.

Следующим шагом является аугментация данных [19], направленная на повышение разнообразия обучающей выборки. В рамках данного этапа применяются различные методы преобразования изображений, такие как поворот, зеркальное отражение, изменение яркости и контрастности, масштабирование и трансляция. Использование этих приемов позволяет модели повысить устойчивость к вариациям визуальных условий, улучшить способность к обобщению, снизить риск переобучения и, как следствие, увеличить точность распознавания и подсчета рыб в реальных условиях эксплуатации.

После тщательной подготовки данных алгоритм переходит к этапу инициализации числа эпох и размера пакета изображений. Число эпох изначально устанавливается равным 1, что соответствует одному полному проходу модели по всему обучающему набору данных. Размер пакета (количество образцов, подаваемых в модель за одну итерацию вычислений) также инициализируется, начиная с 1. После инициализации первый пакет данных подается на вход нейронной сети, и модель выполняет расчет параметров на основе этих данных.

Далее модель осуществляет обнаружение рыб на входных изображениях. Этот этап является ключевым в процессе обучения, так как модель должна определить положение рыб на каждом

изображении, что позволяет вычислить соответствующие значения, такие как вероятность присутствия рыбы в данной области. После выполнения детекции модель вычисляет общую функцию ошибки путем сравнения предсказанных результатов с истинными значениями из обучающего набора данных. Полученная ошибка используется для обновления параметров сети.

Процесс обучения продолжается с использованием алгоритма оптимизации AdamW [20]. AdamW является эффективным методом оптимизации, который позволяет модели корректировать свои параметры таким образом, чтобы функция ошибки снижалась быстрее. AdamW представляет собой усовершенствованную версию алгоритма Adam, включающую регулярное обновление весов для уменьшения переобучения и улучшения способности модели к обобщению. После этапа оптимизации параметров алгоритм вычисляет градиенты функции ошибки и обновляет параметры нейронной сети.

После каждой итерации обучения алгоритм проверяет ряд условий для принятия решения о продолжении процесса обучения. Сначала проверяется количество обработанных пакетов изображений: если оно меньше 64, обучение продолжается; если количество пакетов достигло  $M$ , алгоритм переходит к следующему этапу. Затем, если значение потерь  $e$  уменьшается по истечении каждых 5 эпох, процесс обучения продолжается [21]. Обучение длится до достижения максимального количества

эпох. В противном случае, если значение потерь  $e$  не уменьшается через 5 эпох, алгоритм переходит к этапу сохранения лучшей модели и завершает свою работу.

Когда количество эпох достигает  $N$ , алгоритм завершает обучение и выполняет проверку результатов. Если сни-

жение функции ошибки соответствует заданным требованиям, модель сохраняется. Сохранение модели является критически важным этапом, поскольку после завершения обучения модель используется для обнаружения рыб на новых изображениях или видео без необходимости повторного обучения.




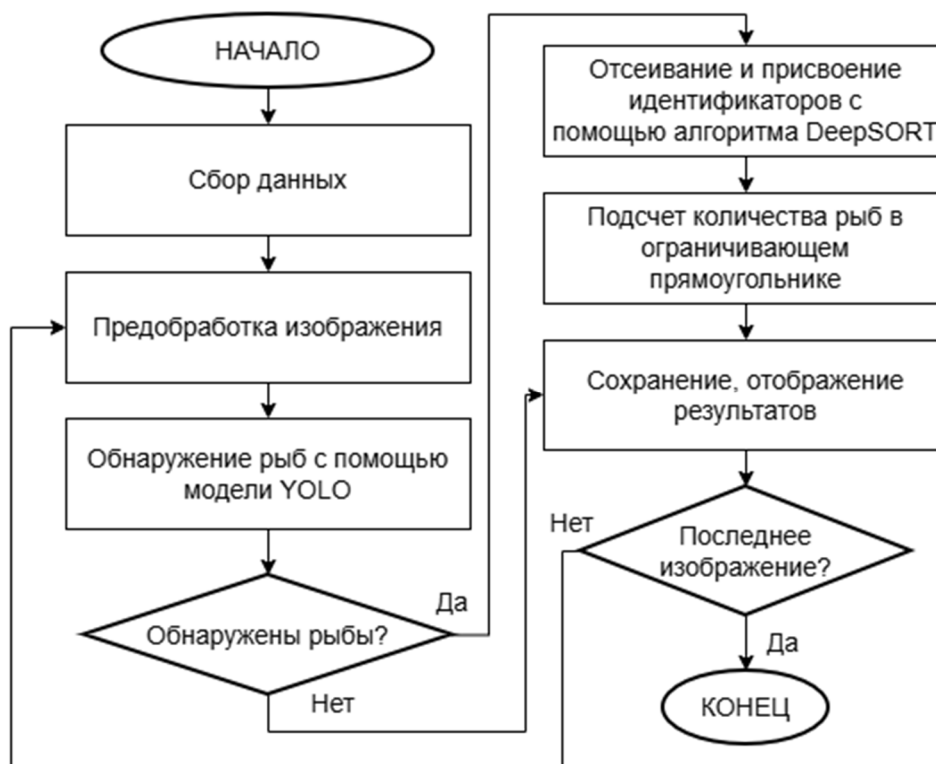
Рис. 1. Алгоритм обучения нейронной модели YOLO

Fig. 1. The YOLO neural model training algorithm

Алгоритм подсчета рыб на изображении и слежения за их движением

Разработанный алгоритм подсчета рыб, представленный на рис. 2, начинается со сбора изображений. После сбора данные проходят предварительную обработку, включающую масштабирование

изображений до стандартного размера  $640 \times 640$  пикселей и нормализацию в диапазоне  $[-1, 1]$  с помощью линейного преобразования, аналогичного процессу нормализации, используемому при обучении модели.



**Рис. 2.** Алгоритм автоматического подсчета рыб с использованием модели YOLO

**Fig. 2.** The automated fish counting algorithm using the YOLO model

Далее для обнаружения рыб используется заранее обученная модель YOLO. При обработке изображения модель формирует ограничивающие рамки вокруг объектов, распознанных как рыбы, и присваивает каждой рамке оценку достоверности, отражающую точность предсказания.

Одним из ключевых этапов является применение метода Non-Maximum Suppression (NMS) [22], который позволяет удалять перекрывающиеся рамки, принадлежащие изображению одной и той же рыбы. Метод NMS сохраняет рамку с наивысшей достоверностью и исключает другие рамки, охватывающие тот же объект, обеспечивая, что каждый экземпляр рыбы будет обнаружен только один раз.

После определения точных рамок каждой рыбе присваивается уникальный идентификатор (*ID*) с использованием алгоритма DeepSORT [23], что позволяет различать объекты и отслеживать движение каждого экземпляра через последовательные кадры.

Данный процесс не только обеспечивает обнаружение и классификацию рыб, но и позволяет подсчитывать их количество путем суммирования всех обнаруженных ограничивающих рамок. Полученные результаты сохраняются и отображаются в реальном времени, что предоставляет пользователю возможность точно контролировать и оценивать численность рыб.

Разработанный алгоритм представляет собой полностью автоматизирован-

ный инструмент для подсчета рыб с высокой точностью, который может быть использован в различных практических приложениях, таких как мониторинг и управление аквакультурой, а также экологические исследования. Благодаря своей способности быстрой и точной обработки данных, алгоритм позволяет сократить человеческое вмешательство в процесс наблюдения и одновременно предоставляет ценную информацию для оптимизации процессов разведения рыб.

## Результаты и их обсуждение

### Корпус данных и вычислительное оборудование

Для проведения экспериментальной оценки эффективности обученной модели YOLO в задаче подсчета рыб на подводных видеоданных, в данном исследовании была применена архитектура YOLOv9t [24]. Модель использовалась для детектирования и количественного анализа рыб в естественной среде с использованием части набора данных DeepFish [25], специально разработанного для повышения производительности распознавания объектов в подводных условиях.

Использованный корпус данных включает в общей сложности 400 изображений с аннотированными объектами рыб в сложных условиях съемки. Каждое изображение имеет разрешение  $640 \times 640$  пикселей, что обеспечивает однородность входных данных для модели YOLOv9t. Все изображения снабжены аннотациями ограничивающих рамок и метками классов, точно определяющими

ми локализацию и тип рыб в кадре. Распределение набора данных составило 80% для тренировки, 10% для валидации и 10% для тестирования, что обеспечивает сбалансированное распределение для точной оценки производительности модели.

Процесс обучения модели YOLOv9t осуществлялся на платформе Google Colab с использованием графического ускорителя Tesla T4, что позволило максимально эффективно использовать вычислительные ресурсы для оптимизации производительности модели. Размер пакета был установлен на 64 изображения, обеспечивая эффективное использование памяти GPU. Обучение проводилось в течение 50 эпох, что позволило модели достичь постепенной сходимости и стабильной производительности без переобучения.

### Показатели эффективности алгоритмов

При оценивании эффективности функционирования алгоритмов обнаружения объектов применялись два основных аспекта: точности детекции и сложности модели. Точность детекции измеряется такими метриками, как Точность (Precision -  $P$ ), Полнота (Recall -  $R$ ) и Средняя точность (Average Precision,  $AP$ ), которые оценивают распознающую способность модели. С другой стороны, сложность модели оценивается через размер файла весов и общее количество параметров, что отражает уровень потребления вычислительных ресурсов. В совокупности эти факторы определяют производительность и практическую применимость модели.



Точность определяется как отношение корректно классифицированных ограничивающих рамок целевых объектов к общему количеству обнаруженных рамок, служа ключевым показателем точности алгоритма детекции объектов.

Полнота представляет долю корректно обнаруженных рамок среди общего количества фактических целевых рамок, измеряя степень охвата и способность алгоритма к извлечению объектов.

Средняя точность представляет собой комплексный показатель оценки, используемый для объективной оценки производительности моделей детекции объектов при различных порогах Пересечения по Объединению (IoU). AP вычисляется путем расчета площади под кривой Точность-Полнота (Precision-Recall curve). Конкретно, для каждой категории объектов набор значений Точности и Полноты вычисляется на основе различных порогов IoU. Этот набор значений затем интерполируется для расчета площади под кривой, представляющей AP для данной категории.

*mAP*-средняя точность (*mAP* – Mean Average Precision) служит комплексным метрическим показателем, получаемым путем усреднения площадей под кривыми Точность-Полнота для различных категорий. *mAP* является одной из наиболее широко используемых метрик оценки производительности в области детекции объектов, обеспечивая интегральную оценку Точности и Полноты модели. Обычно *mAP* вычисляется для серии порогов IoU, таких как 0.5 и 0.95, для оценки произ-

водительности при различных пороговых значениях.

Предположим, что количество истинно-положительных образцов в результатах прогнозирования обозначается как *TP* (True Positives), количество ложно-положительных образцов представляется как *FP* (False Positives), а количество ложно-отрицательных образцов указывается как *FN* (False Negatives), где *i* обозначает категорию в наборе данных. На основе данных определений, уравнения для расчета Точности (*P*), Полноты (*R*) и Средней Точности (*mAP*) выражаются следующим образом:

$$R = \frac{TP}{TP + FN}$$


$$P = \frac{TP}{TP + FP}$$

$$AP = \int_0^1 P(R) dR,$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i.$$

### Экспериментальные результаты

На рис. 3 представлены кривые потерь на обучающей и валидационной выборках, иллюстрирующие процесс сходимости модели YOLOv9t в ходе обучения. Обе кривые демонстрируют устойчивую тенденцию к снижению, что свидетельствует об эффективном протекании процесса оптимизации и отсутствии выраженного переобучения. Стабильная производительность модели, отраженная в метриках Точность, Полнота и *mAP*, подтверждает ее надежность при решении задачи обнаружения рыб.



**Рис. 3.** Кривые потерь на обучении и валидации для YOLOv9t

**Fig. 3.** Training and validation loss curves for YOLOv9t


Для всесторонней оценки способности модели обнаруживать рыбу при различных порогах уверенности, нами были

проанализированы посемейные кривые F1 (рис. 4). Показатель F1 выступает в качестве агрегированной метрики, отра-

жающей общую производительность модели посредством балансировки между точностью и полнотой. Оптимальное значение F1, равное 0.93, достигается при пороге уверенности приблизительно 0.356, что указывает на наилучший баланс между точностью и полнотой на данном уровне и обуславливает применимость модели в приложениях, требующих оптимизации F1-score.

Эксперименты на наборе данных DeepFish с использованием модели YOLOv9t показали высокие результаты:

точность составила 0,928, Полнота — 0,91, mAP50 - 0,961, а mAP50-95 - 0,584. Эти показатели демонстрируют, что YOLOv9t эффективно распознает рыб в различных условиях среды, включая прозрачную и мутную воду, а также ситуации с низкой контрастностью. Несмотря на то, что такие факторы, как изменение освещения или тени, могут снижать качество обнаружения, YOLOv9t сохраняет высокую точность и быструю обработку.



**Рис. 4.** Кривая F1-Confidence для модели YOLOv9t

**Fig. 4.** The F1-Confidence curve for the YOLOv9t model

С имеющимися всего 2005603 параметрами и 7,8 GFLOPs, модель YOLOv9t превосходит традиционные методы в задачах обнаружения и подсчета рыб, сочетая высокую производительность с оптимальной вычислительной эффективностью. Результаты экспериментов показывают, что модель обеспечивает

высокую точность обнаружения и подсчета, особенно когда рыбы не слишком скрыты или перемещаются явно в кадре. Одним из ключевых факторов, способствующих высокой точности YOLOv9t, является способность быстро и точно обрабатывать рамки, ограничивающие объекты, минимизируя ошибки в слож-

ных ситуациях, например, при малых размерах объектов или их частичном перекрытии другими предметами.


Кроме того, YOLOv9t демонстрирует высокую эффективность в сложных сценариях, таких как присутствие нескольких рыб в одном кадре или быстрое движение объектов. Методы, такие как Non-Maximum Suppression, и усовершенствования модели YOLOv9t позволяют устранять ложные срабатывания и минимизировать дублирование,

обеспечивая корректное распознавание и подсчет каждой рыбы.


Для подсчета количества рыб, после обнаружения и маркировки объектов в каждом кадре, YOLOv9t использует алгоритм DeepSORT для присвоения уникального идентификатора каждой рыбе. Этот процесс позволяет отслеживать каждую особь на последовательных кадрах без дублирования при подсчете. На рис. 5 представлены примеры подсчета рыб с использованием модели YOLOv9t.



(a)



(б)



**Рис. 5.** Результаты подсчета рыб с использованием модели YOLO: **а** – исходные изображения; **б** – изображения после обработки моделью YOLOv9t

**Fig. 5.** Fish counting results using the YOLO model: **a** – original images; **b** – images after processing by the YOLOv9t model

На изображении модель обнаруживает рыб и выводит результаты подсчета 8 и 4, что соответствует действительности. Результаты показывают, что система обеспечивает точный подсчет об-

щего количества рыб, одновременно отображая результаты на пользовательском интерфейсе и поддерживая высокую производительность на протяжении всего процесса обработки.

Полученные результаты экспериментов продемонстрировали, что YOLOv9t является не только мощным инструментом для обнаружения рыб под водой, но и эффективным решением для задач подсчета рыб в естественной среде. Это открывает значительный потенциал для применения в таких областях, как экологические исследования, охрана дикой природы и управление аквакультурой, где отслеживание и мониторинг численности рыб имеют критически важное значение.

## Выводы

В статье представлен алгоритм обучения модели YOLO и алгоритм автоматического подсчета рыб с использованием модели YOLO. Для тестирования разработанных алгоритмов были проведены эксперименты по оценке эффективности обученной модели YOLOv9t при решении задачи обнаружения и подсчета рыб на подводных видеозаписях с использованием стандартного набора данных DeepFish. Ключевым фактором успеха системы является метод Non-Maximum Suppression, который эффективно фильтрует перекрывающиеся или дублирующие области обнаружения, оставляя только ограничивающую рамку с наивысшей вероятностью для каждого объ-

екта, что делает результаты обнаружения более точными и надежными. Экспериментальные результаты служат убедительным доказательством эффективности модели, демонстрируя превосходные показатели: Точность - 0,928, Полнота - 0,91, mAP50 - 0,961 и mAP50-95 - 0,584. Примечательно, что модель YOLOv9t достигает таких впечатляющих показателей при крайне оптимизированной архитектуре, имея всего 2 005 603 параметра и 7,8 GFLOPs, что подтверждает ее преимущества не только с точки зрения точности, но и вычислительной эффективности, позволяя использовать модель на ограниченном аппаратном обеспечении. Для задачи подсчета рыб в исследовании успешно применен алгоритм DeepSORT. После того как YOLOv9t обнаруживает объекты в каждом кадре, каждому объекту присваивается уникальный идентификатор. Система затем отслеживает перемещение объектов по последовательным кадрам на основе корреляции их положения, размера и визуальных признаков. Интеллектуальное управление жизненным циклом объектов (отслеживание появления, исчезновения и поддержание ID) минимизирует ошибки дублирующего подсчета или пропуска объектов, обеспечивая точный и стабильный подсчет общего числа рыб в видео.

## Список литературы

1. Overview of smart aquaculture system: Focusing on applications of machine learning and computer vision / T.T.E. Vo, H. Ko, J. H. Huh, Y. Kim // Electronics. 2021. Vol. 10(22). P. 2882.

2. Ji Y., et al. Design and realization of a novel hybrid-drive robotic fish for aquaculture water quality monitoring // *Journal of Bionic Engineering*. 2023. Vol. 20.2. P. 543-557.
3. Kruusmaa M., et al. Salmon behavioural response to robots in an aquaculture sea cage // *Royal Society open science*. 2020. Vol. 7.3. P. 191220.
4. Rastegari H., et al. Internet of Things in aquaculture: A review of the challenges and potential solutions based on current and future trends // *Smart Agricultural Technology*. 2023. Vol. 4. P. 100187.
5. Mandal A., Apurba R.G. Role of artificial intelligence (AI) in fish growth and health status monitoring: A review on sustainable aquaculture // *Aquaculture International*. 2024. Vol. 32.3. P. 2791-2820.
6. Ле В.Н., Ронжин А.Л. Обзор интеллектуальных систем управления и робототехнических задач в производстве аквакультуры // *Морские интеллектуальные технологии*. 2024. Vol. 63. P. 171–180.
7. Chiu M.C., et al. Development of smart aquaculture farm management system using IoT and AI-based surrogate models // *Journal of Agriculture and Food Research*. 2022. Vol. 9. P. 100357.
8. Ронжин А.Л., Ле В.Н., Шувалов Н. Оптимизация технологической карты допустимых системотехнических решений задачи видеоаналитики аквакультуры // *Вестник Южно-Уральского государственного университета*. 2024. Т. 16. С. 50-58.
9. Yang L., et al. Computer vision models in intelligent aquaculture with emphasis on fish detection and behavior analysis: a review // *Archives of Computational Methods in Engineering*. 2021. Vol. 28.4.
10. Quaade S., et al. Remote sensing and computer vision for marine aquaculture // *Science Advances*. 2024. Vol. 10.42.
11. Le V.N., Tuyen T. V., Ronzhin A. L. Fish image classification based on MobileNetV2 with transfer learning technique for robotic application in aquaculture // *International Conference on Interactive Collaborative Robot*. 2024. P. 201-212.
12. Tran T., Duong B., Vu Q., Le V., Glibko O., Ronzhin A. Methods and Technical Means of Nonintrusive Assessment of Fish Bio-mass and Robotic Maintenance of Cage Aquaculture // *International Conference on Agriculture Digitalization and Organic Production*. 2024. P. 207-215.
13. Terven J., Diana-Margarita C., Julio-Alejandro R. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS // *Machine Learning and Knowledge Extraction*. 2023. Vol. 5.4. P. 1680–1716.
14. Zhang Z., et al. A method for counting fish based on improved YOLOv8 // *Aquacultural Engineering*. 2024. Vol. 107. P. 102450.
15. Yu H., et al. An automatic detection and counting method for fish lateral line scales of underwater fish based on improved YOLOv5 // *IEEE*. 2023. P. 143616-143627.

16. Ле В.Н., Ронжин А.Л. Способы и технические средства позиционирования и навигации роботов в водной среде // Известия Кабардино-Балкарского научного центра РАН. 2023. Т. 6(116). С. 167–178.
17. Wu J. Introduction to convolutional neural networks // National Key Lab for Novel Software Technology. 2017. P. 495.
18. Khanam R., Muhammad H. A Review of YOLOv12: Attention-Based Enhancements vs. Previous Versions // arXiv preprint arXiv:2504.11995. 2025.
19. Shorten C., Taghi, M. K. A survey on image data augmentation for deep learning // Journal of Big Data. 2019. Vol. 6(1). P. 1–48.
20. Zhuang Z., et al. Understanding AdamW through proximal methods and scale-freeness // arXiv preprint arXiv:2202.00089. 2022.
21. Prechelt L. Early stopping—but when? // Neural Networks: Tricks of the trade. 2002. P. 55–69.
22. Hosang J., Rodrigo B., Bernt S. Learning non-maximum suppression // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017.
23. Wojke N., Alex B., Dietrich P. Simple online and realtime tracking with a deep association metric // 2017 IEEE International Conference on Image Processing (ICIP). 2017.
24. Wang C., Hau Y., Hong-Yuan M.L. Yolov9: Learning what you want to learn using programmable gradient information // European conference on computer vision. 2024.
25. Saleh A., et al. A realistic fish-habitat dataset to evaluate algorithms for underwater visual analysis // Scientific reports. 2020. P. 14671.

## References

1. Vo T. T. E., Ko H., Huh J. H., Kim Y. Overview of smart aquaculture system: Focusing on applications of machine learning and computer vision. *Electronics*. 2021; 10(22): 2882.
2. Ji, Yiting, et al. Design and realization of a novel hybrid-drive robotic fish for aquaculture water quality monitoring. *Journal of Bionic Engineering*. 2023; 20.2: 543-557.
3. Kruusmaa Maarja, et al. Salmon behavioural response to robots in an aquaculture sea cage. *Royal Society open science*. 2020; 7.3: 191220.
4. Rastegari Hajar, et al. Internet of Things in aquaculture: A review of the challenges and potential solutions based on current and future trends. *Smart Agricultural Technology*. 2023; 4: 100187.
5. Mandal Arghya, Apurba Ratan Ghosh. Role of artificial intelligence (AI) in fish growth and health status monitoring: A review on sustainable aquaculture. *Aquaculture International*. 2024; 32.3: 2791-2820.

6. Le V. N., Ronzhin A. L. A Review of Intelligent Control Systems and Robotics Applications in Aquaculture Production. *Morskiye intellektual'nyye tekhnologii = Marine intelligent technologies*. 2024; 63: 171–180. (In Russ.).

7. Chiu Min-Chie, et al. Development of smart aquaculture farm management system using IoT and AI-based surrogate models. *Journal of Agriculture and Food Research*, 2022; 9: 100357.

8. Ronzhin A. L., Le V. N., Shuvalov N. Optimization of the process map of admissible system-technical solutions for the problem of video analytics in aquaculture. *Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta = Bulletin of the South Ural State University*. 2024; 16: 50-58. (In Russ.).

9. Yang Ling, et al. Computer vision models in intelligent aquaculture with emphasis on fish detection and behavior analysis: a review. *Archives of Computational Methods in Engineering*, 2021; 28.4.

10. Quaade Sebastian, et al. Remote sensing and computer vision for marine aquaculture. *Science Advances*, 2024; 10.42.

11. Van Nghia, Le, Tran Van Tuyen, Andrey Ronzhin. Fish image classification based on MobileNetV2 with transfer learning technique for robotic application in aquaculture. In: *International Conference on Interactive Collaborative Robotics*. 2024. P. 201-212.

12. Tran T., Duong B., Vu Q., Le V., Glibko O., Ronzhin A. L.. Methods and Technical Means of Nonintrusive Assessment of Fish Biomass and Robotic Maintenance of Cage Aquaculture. *International Conference on Agriculture Digitalization and Organic Production*. 2024. 207-215.

13. Terven Juan, Diana-Margarita Córdova-Esparza, Julio-Alejandro Romero-González. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. 2023; 5.4: 1680–1716.

14. Zhang Zhenzuo, et al. A method for counting fish based on improved YOLOv8. *Aquacultural Engineering*. 2024; 107: 102450.

15. Yu Huihui, et al. An automatic detection and counting method for fish lateral line scales of underwater fish based on improved YOLOv5. *IEEE*, 2023. P. 143616-143627,

16. Le V. N., Ronzhin A. L. Methods and technical means of positioning and navigation of robots in the aquatic environment. *Izvestiya Kabardino-Balkarskogo nauchnogo tsentra RAN = Bulletin of the Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences*. 2023; 6(116): 167–178 (In Russ.).

17. Wu Jianxin. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology*. 2017. P. 495.

18. Khanam Rahima, Muhammad Hussain. A Review of YOLOv12: Attention-Based Enhancements vs. Previous Versions. *arXiv preprint arXiv:2504.11995*, 2025.



19. Shorten Connor, Taghi M. Khoshgoftaar. A survey on image data augmentation for deep learning. *Journal of big data*. 2019; 6(1): 1–48.
20. Zhuang Zhenxun, et al. Understanding AdamW through proximal methods and scale-freeness. arXiv preprint arXiv:2202.00089, 2022.
21. Prechelt L. Early stopping—but when? *Neural Networks: Tricks of the trade*. 2022. P. 55–69.
22. Hosang Jan, Rodrigo Benenson, Bernt Schiele. Learning non-maximum suppression. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
23. Wojke Nicolai, Alex Bewley, Dietrich Paulus. Simple online and realtime tracking with a deep association metric. In: *2017 IEEE International Conference on Image Processing (ICIP)*, 2017.
24. Wang Chien-Yao, I-Hau Yeh, Hong-Yuan Mark Liao. Yolov9: Learning what you want to learn using programmable gradient information. In: *European conference on computer vision*, 2024.
25. Saleh Alzayat, et al. A realistic fish-habitat dataset to evaluate algorithms for underwater visual analysis. In: *Scientific reports*. 2020. P. 14671.

---

### Информация об авторе / Information about the Author

**Ле Ван Нгиа**, аспирант, Санкт-Петербургский  
Федеральный исследовательский центр  
Российской академии наук,  
г. Санкт-Петербург, Российская Федерация,  
e-mail: lenghia18071999@gmail.com

**Le Van Nghia**, Post-Graduate Student,  
St. Petersburg Federal Research Center  
of the Russian Academy of Sciences,  
St. Petersburg, Russian Federation,  
e-mail: lenghia18071999@gmail.com