

МЕТОДИЧЕСКИЕ АСПЕКТЫ РЫБОХОЗЯЙСТВЕННЫХ ИССЛЕДОВАНИЙ

УДК 597.552.511(282.257.21):528.7
EDN YZCAHН

DOI: 10.36038/0234-2774-2025-26-4-103-112

ПРИМЕНЕНИЕ МЕТОДОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ
ДЛЯ АЭРОВИЗУАЛЬНОГО УЧЁТА ПРОИЗВОДИТЕЛЕЙ
НЕРКИ С БОРТА БЕСПИЛОТНОГО ЛЕТАТЕЛЬНОГО
АППАРАТА (БПЛА) В БАССЕЙНЕ ОЗ. АЗАБАЧЬЕ В 2024 Г.

© 2025 г. А.С. Потапов (spin: 7105-0890), Е.С. Фадеев (spin: 7369-0194),
К.М. Малых (spin: 7357-3091)

Камчатский филиал ГНЦ РФ ФГБНУ «ВНИРО» (КамчатНИРО),
Россия, Петропавловск-Камчатский, 683000
E-mail: a.potapov@kamniro.vniro.ru

Поступила в редакцию 7.08.2025 г.

Оценена эффективность методов компьютерного зрения для аэровизуального учёта производителей нерки на ключевых нерестилищах оз. Азабачье в 2024 г. Проанализированы модели компьютерного зрения, которые могут быть применены для выполнения поставленной задачи и выбрана наиболее подходящая. Определены оптимальные критерии отбора фото и видеоматериалов, собираемых для обучения модели компьютерного зрения.

Ключевые слова: тихоокеанские лососи, производители нерки, озеро Азабачье, аэровизуальный учёт, БПЛА, компьютерное зрение, модель обнаружения.

ВВЕДЕНИЕ

Учёт численности производителей тихоокеанских лососей в водных объектах Камчатского края представляет собой важную задачу, имеющую фундаментальное значение для сохранения запасов, рационального управления рыбным промыслом и точного прогнозирования возвратов.

В последние годы внедрение беспилотных летательных аппаратов (БПЛА) в практику рыбохозяйственных исследований открыло новые перспективы для решения прикладных задач мониторинга (Свиридов и др., 2022). По данным исследований, использование БПЛА позволяет получать высоко-детализированные данные о распределении и численности рыб на нерестилищах (Запорожец, Запорожец, 2017; Фадеев, 2019; Свиридов и др., 2022; Свиридов, Поваров, 2024).

Внедрение современных технологий, включая методы компьютерного зрения и машинного обучения, позволяет сущест-

венно повысить качество учётных работ на модельных водоёмах. Разработчиками алгоритмов на основе нейронных сетей (таких как YOLOv8) заявлено, что они демонстрируют высокую точность обнаружения объектов при обработке аэрофотоснимков (<https://docs.ultralytics.com/ru>).

Автоматизированные системы учёта производителей нерки с помощью БПЛА и компьютерного зрения могут быть особенно эффективны для:

- Автоматизации процесса учёта производителей;
- Мониторинга труднодоступных нерестилищ;
- Изучения пространственного распределения рыб на нерестилищах.

Цель работы: оценить возможность применения методов компьютерного зрения для автоматизации процесса учёта нерки в бассейне оз. Азабачье в 2024 г. с борта беспилотных летательных аппаратов.

Для достижения этой цели были поставлены следующие задачи:

1. Проанализировать массивы фото и видеоматериалов, полученных с помощью потребительских моделей беспилотных летательных аппаратов;
2. Обучить модель искусственного интеллекта для обнаружения и учёта производителей нерки на фотоснимках;
3. Провести сравнительный анализ результатов счёта производителей нерки на фотоснимках вручную и методом компьютерного зрения.

МАТЕРИАЛ И МЕТОДИКА

Обнаружение объектов на фото и видео – это важная задача в области компьютерного зрения, которая включает идентификацию и локализацию объектов в изображениях или видеопотоках. Существует множество моделей и алгоритмов, которые используются для этих целей. Выбор модели для обнаружения объектов, подходящей для настоящей цели, является основополагающей задачей для данной работы. Для этого был проведён сравнительный анализ характеристик популярных моделей компьютерного зрения (табл. 1).

После тщательного анализа, в качестве исходной модели обнаружения объектов,

выбран алгоритм YOLO (You Only Look Once), представленный в 2015 г. в исследовательской работе «You Only Look Once: Unified, Real-Time Object Detection» (Redmon et al, 2015). Оптимальное соотношение скорости и точности YOLO демонстрирует выдающуюся производительность (до 150 FPS на GPU) при сохранении высокой точности (50–80% mAP). Благодаря поддержке популярных фреймворков (PyTorch, TensorFlow) и наличию готовых решений, YOLO может быть относительно быстро интегрирована в существующие проекты. Для базового использования достаточно всего нескольких строк кода. Модель демонстрирует хорошую производительность даже на относительно слабом оборудовании, что делает её доступной для широкого круга пользователей.

Обучение сегментационной модели YOLO на пользовательских данных – это сложный многоступенчатый процесс, требующий особой внимательности на каждом этапе. Основные стадии обучения включают подготовку данных, конфигурацию модели и непосредственно процесс тренировки нейросети (<https://docs.ultralytics.com/ru>).

На начальном этапе необходимо тщательно подготовить обучающую выборку изображений. Ключевое значение имеет раз-

Таблица 1. Основные характеристики анализируемых моделей компьютерного зрения

Модель	Тип задачи	Скорость (FPS)	Точность (mAP)	Сложность освоения	Особенности
Haar Cascades	Обнаружение объектов	50–100+	Низкая (40–60%)	Низкая	Устаревший метод, требует каскадов
YOLO (v8)	Обнаружение объектов	30–150+	Высокая (50–80%)	Средняя	Оптимальный баланс скорости и точности
SSD	Обнаружение объектов	20–80	Средняя (60–75%)	Средняя	Для мобильных устройств
Faster R-CNN	Обнаружение объектов	5–15	Очень высокая (70–85%)	Высокая	Медленный, но точный
Mask R-CNN	Сегментация + обнаружение	1–10	Очень высокая (75+%)	Очень высокая	Добавляет маски объектов
U-Net	Сегментация изображений	10–30	Высокая (для сегментации)	Средняя	Специализированный под медицинские данные

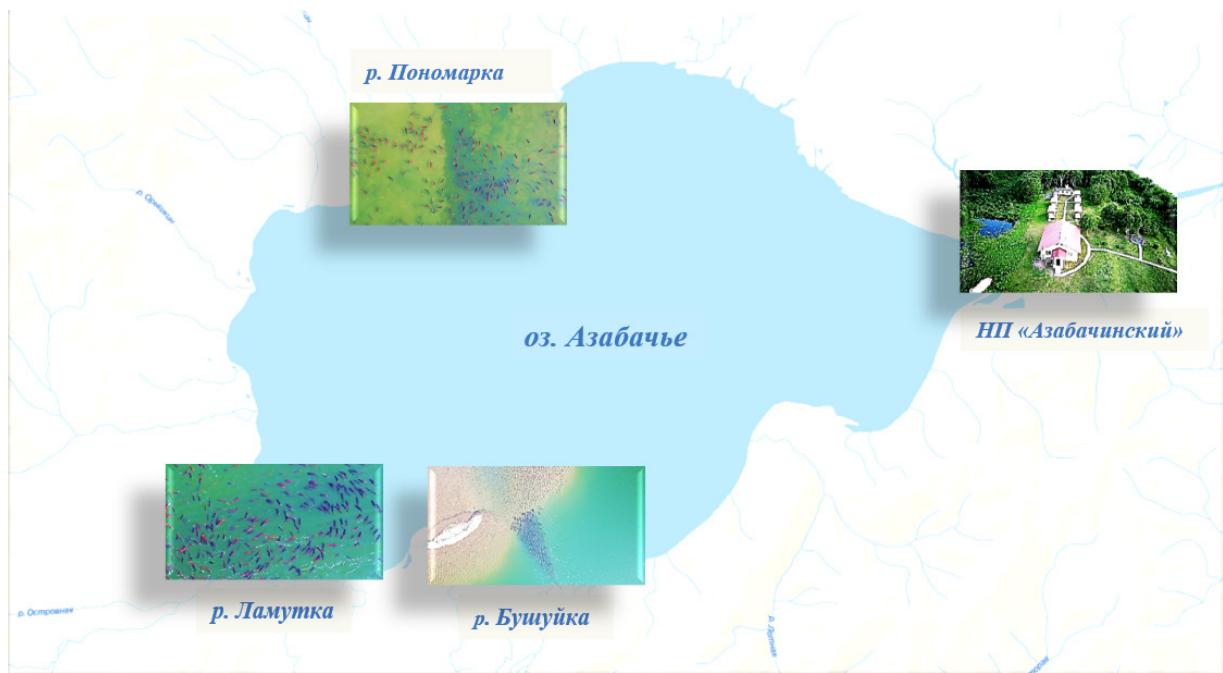


Рис. 1. Места проведения аэровизуальных исследований в бассейне оз. Азабачье в 2024 г.

нообразие данных: снимки должны демонстрировать целевые объекты в различных условиях, под разными углами освещения и на отличающемся фоне. Это позволяет модели научиться достоверно распознавать объекты в реальных условиях.

Для наблюдений за миграцией нерки на нерестилища использовали аэрофотосъёмку, которую осуществляли с помощью квадрокоптера DJI Mini 3 Pro (Dajiang Innovation Technology Co, КНР). Фото и видеоматериалы были собраны в бассейне оз. Азабачьего на реках Бушуйка, Ламутка и Пономарка (рис. 1). Съёмку проводили с высоты 30–50 м.

Снимки, сделанные с помощью БПЛА, были обработаны в стандартных программах просмотра изображений Windows 10 (Microsoft Corporation, США) и свободно распространяемой программе «ImageJ» (National Institutes of Health, США) (Whitehead et al., 2014; Christie et al., 2016; Groves et al., 2016; Запорожец, Запорожец, 2017).

С помощью раскадровки собранных аэрофотоснимков было отобрано 450 кадров. Для обучения модели такого количества материала было недостаточно, поэтому набор

было решено увеличить при помощи аугментации – поворота фотографий на 45 и 90 градусов относительно центра оригинала. Стоит заметить, что для обучения первого поколения модели отбирались видеокадры, полученные в солнечную погоду и имеющие наименьшее количество бликов. Также немаловажно то, что на наблюдаемых водоёмах вода имела минимальную мутность.

Особое внимание следует уделить процессу разметки данных, так как от её качества напрямую зависит результат обучения. В зависимости от поставленной задачи можно использовать либо полигональную разметку, обводящую контуры объектов, либо ограничивающие рамки (bounding boxes). Полигоны обеспечивают более точное выделение контуров объекта, тогда как прямоугольные рамки, определяемые всего двумя точками (левый верхний и правый нижний углы), проще в создании и обработке.

Формирование набора данных и разметку аэрофотоснимков производили в свободно распространяемом приложении «X-AnyLabeling» (Wei Wang, 2023). Существующие предобученные модели, доступные в

открытых источниках, способны детектировать множество объектов: от человеческих силуэтов до животных, транспорта и других предметов. Однако задача обнаружения рыб – более узкоспециализированная, поэтому в ходе работы над проектом предобученные модели не использовались (Малых и др., 2024, 2025). Авторами создавалась новая модель, предназначенная для выполнения конкретной задачи – обнаружение рыб на фоне дна реки, бликов и ряби на поверхности воды. В ходе разработки проекта количество классов целевых объектов сведено к одному – нерке в нерестовом окрасе.

Размеченные аэрофотоснимки и сопутствующая информация о местоположении и форме рыб были разделены на три набора: тренировочный, проверочный и тестовый. В процессе анализа тренировочного набора модель учится распознавать закономерности и признаки, которые помогают ей идентифицировать рыб на изображениях, обобщать эту информацию и применять её для обнаружения рыб в проверочном наборе. Проверочный набор в свою очередь используется для промежуточной оценки, что помогает контролиро-

вать процесс обучения и избежать переобучения модели. Тестовый набор использовали для проверки адекватности полученной модели после процесса обучения.

Обучение модели на пользовательских изображениях представляет собой циклический процесс, который начинается с инициализации начальных весовых коэффициентов. На каждом этапе обучения система последовательно выполняет несколько ключевых операций: входные изображения вместе с их разметкой подаются в нейронную сеть, где рассчитываются функции потерь путём сравнения предсказаний модели с эталонными данными. С помощью механизма обратного распространения ошибки происходит корректировка весовых параметров сети, что позволяет постепенно уменьшать величину потерь и повышать точность предсказаний. В процессе обучения модель учится выделять значимые области на изображениях, точно определяя местоположение целевых объектов и их принадлежность к определённым классам (рис. 2).

Фундаментальной единицей процесса обучения является эпоха – это полный цикл

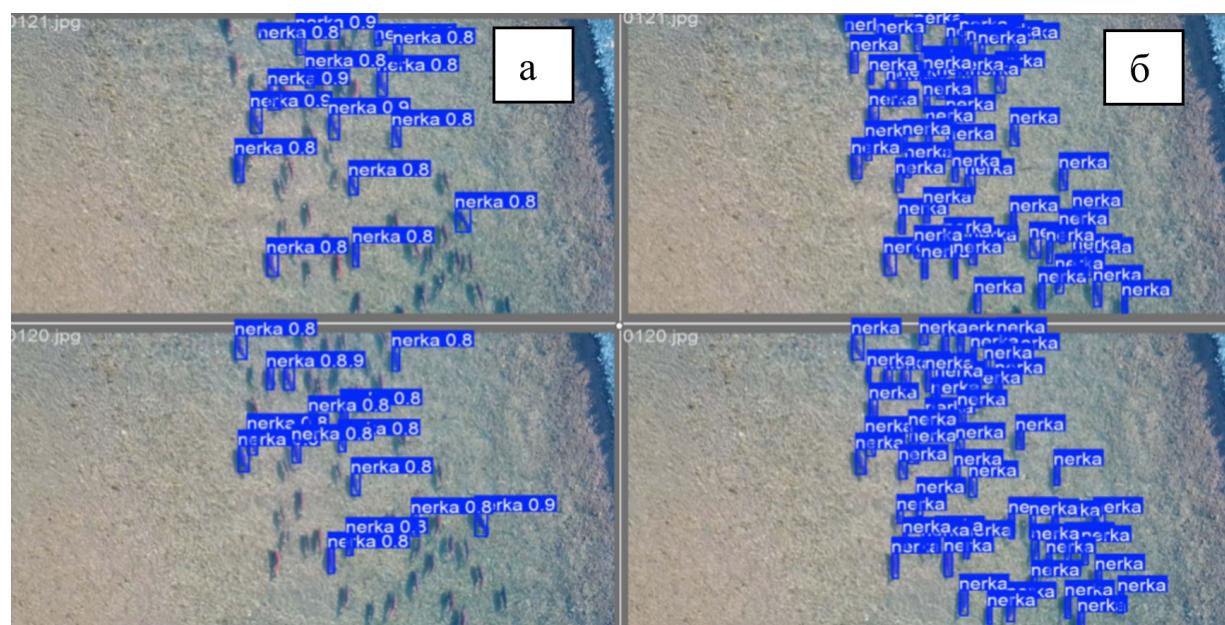


Рис. 2. Фотографии из проверочного набора с отмеченными производителями нерки: а – программой во время первых эпох; б – вручную.

обработки всего обучающего набора, в течение которого каждый пример данных проходит через нейронную сеть, внося корректификы в её параметры. Количество эпох является критически важным гиперпараметром: их недостаток приводит к недобору точности, тогда как избыток может вызвать переобучение модели. В ходе обучения система в реальном времени отображает в командной строке техническую информацию, включая время выполнения и динамику ключевых показателей эффективности.

После завершения каждой эпохи осуществляется этап валидации, когда производительность модели проверяется на проверочном наборе данных, не участвовавшем в обучении. Для комплексной оценки качества работы модели используются три основные метрики: *precision* (точность), отражающая долю, верно идентифицированных объектов среди всех обнаруженных; *recall* (чувствительность), отражающая способность модели обнаруживать все релевантные объекты и *mAP* (порог пересечения объектов), которая интегрирует оба предыдущих показателя в единую объективную оценку эффективности модели. Совместное использование этих метрик позволяет всесторонне оценить способность модели к обнаружению объектов на новых, ранее не встречавшихся изображениях.

Процесс обучения выполняется в командной строке свободно распространяемого программного продукта «Anaconda» (Anaconda Inc., США) с установленной библиотекой «ultralytics». По окончании обучения модели алгоритм формирует файл весов, имеющий расширение *.pt*, рассчитывает и выводит графики показателей обучения и качества модели по всем этапам. Каждой модели присваивалось название, содержащее целевой вид рыб (*nerka*), номер версии алгоритма *YOLO* (*y8*), и имя исходного файла (*p*, *m* или *s*). В дальнейшей работе к названию моделей добавляли суффикс «*_seg*», обозначающий способность к сегментации изображений.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЯ

В результате обработки размеченных аэрофотоснимков была обучена модель, способная эффективно идентифицировать особей нерки на нерестилищах. Особенностью проведённого исследования стало сравнение эффективности обучения модели с использованием различных методов разметки объектов: полигональной и ограничивающей прямоугольной рамки.

Сравнительный анализ показал, что наилучшие результаты были достигнуты при обучении модели с использованием прямоугольных рамок и критерия пересечения (*IoU – Intersection over Union*) в 50%. В этом случае модель продемонстрировала наивысшую достоверность – 86% (рис. 3). Мы предполагаем, что преимущество данного метода обусловлено ограниченным объёмом обучающей выборки: при недостатке данных прямоугольная разметка позволяет обобщать признаки объектов лучше, чем полигональная. Несмотря на то, что полигональный метод считается более точным (особенно при наличии большого количества обучающих изображений), в условиях ограниченного числа исходных данных он может уступать по эффективности более простым способам аннотирования.

Для более детального анализа качества модели была построена матрица ошибок (*confusion matrix*), представляющая собой один из стандартных инструментов оценки качества в задачах детекции объектов, в том числе при использовании алгоритмов семейства *YOLO*. В данной матрице по горизонтали отображаются предсказанные классы, по вертикали – истинные. Анализ показал, что на проверочном наборе данных, модель верно обнаружила 938 особей нерки (истинно положительные срабатывания), пропустила 146 особей (ложно отрицательные), а также 182 раза ошибочно классифицировала фоновые объекты (например, ветки, блики на воде и пр.) как нерку (ложно положительные) (рис. 4).

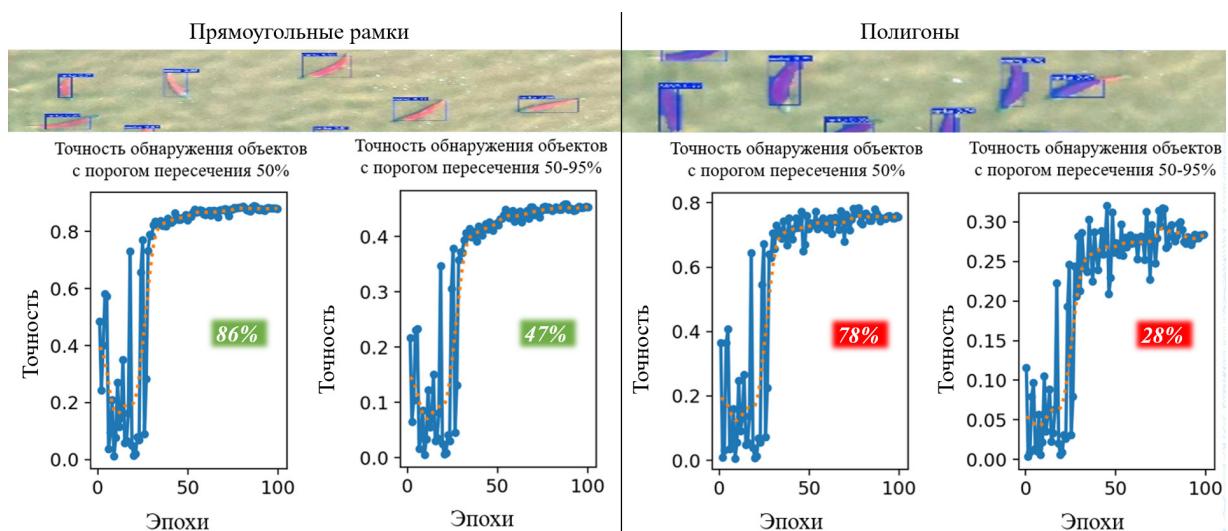


Рис. 3. Метрики модели после процесса обучения распознавания рыб.

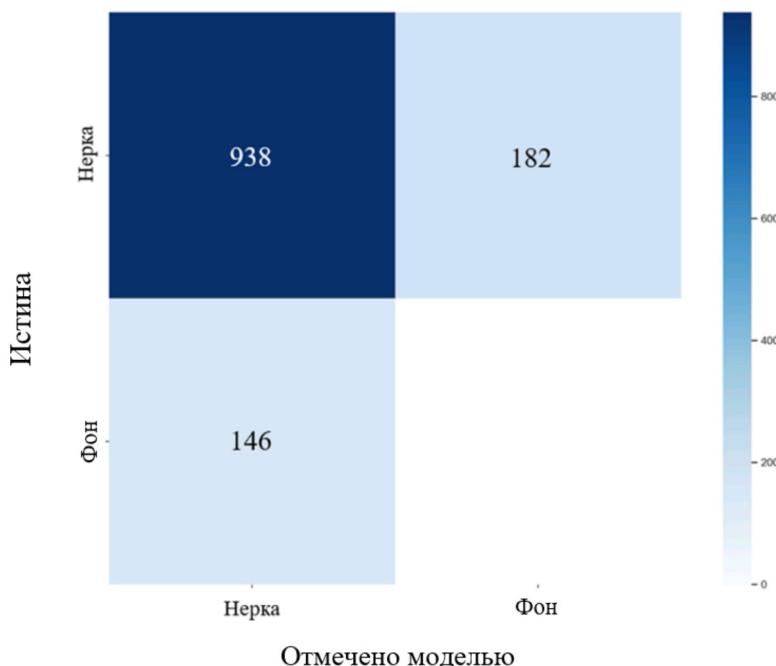


Рис. 4. Матрица ошибок модели.

Такие ошибки могут быть связаны с визуальной схожестью производителей нерки с некоторыми фоновыми элементами в условиях естественной среды, особенно при наличии отражений на водной поверхности или при высокой плотности скоплений рыб.

Для окончательной оценки обобщающей способности и точности автоматиче-

ского подсчёта проведён тест модели на ранее не использовавшемся контрольном изображении – фотографии, полученной с БПЛА в оптимальных условиях и в максимальном разрешении.

Сначала идентификация и счёт производителей нерки на тестовом изображении выполнялись вручную с использованием спе-



Рис. 5. Подсчёт производителей нерки ручным методом.

Таблица 2. Сравнительный анализ счёта ручным методом и счёта с помощью модели компьютерного зрения

Метод	Количество выявленных рыб на снимке, экз.		Погрешность, %	Время обработки, сек.
	Истинно положительные, экз.	Ложно положительные, экз.		
Ручной счёт	887	0	0	600
Счёт методом прямоугольной рамки	841	61	12	1
Счёт полигональным методом	764	90	24	1

циализированного программного обеспечения ImageJ (рис. 5). Данный вид разметки рассматривался как эталонный. В результате было зафиксировано 887 особей рыб, а счёт занял около 10 мин. Поскольку каждый экземпляр визуально идентифицировался оператором, ручной метод позволил полностью исключить как ложноположительные, так и ложноотрицательные срабатывания (табл. 2).

Далее обученная модель компьютерного зрения была применена при двух подходах к аннотированию данных: с помощью ограничивающих прямоугольных рамок и полигональной сегментации (рис. 6, 7, табл. 2).

Вариант, основанный на методе ограничивающих рамок, позволил обнаружить 841 объект, из них 61 был ошибочно классифици-

рован как рыба, в то время как часть настоящих рыб осталась нераспознанной. Общее время обработки изображения составило 1 с. Погрешность относительно эталонного (ручного) подсчёта составила 12%. Наличие пропущенных объектов в основном объясняется влиянием внешних факторов, таких как рябь на водной поверхности и высокая плотность размещения особей, что приводило к их частичному перекрытию.

При варианте использования модели сегментации объектов, было зафиксировано 764 особи, при этом количество ложноположительных срабатываний составило 90. Как и в первом варианте, время обработки изображения не превышало 1 с, однако погрешность по отношению к ручному методу составила уже

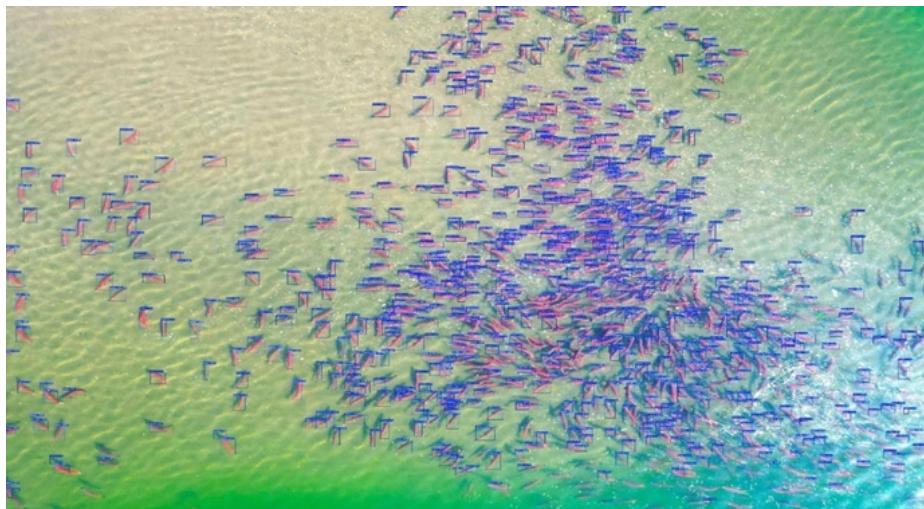


Рис. 6. Подсчёт производителей нерки методом прямоугольной (ограничивающей) рамки.

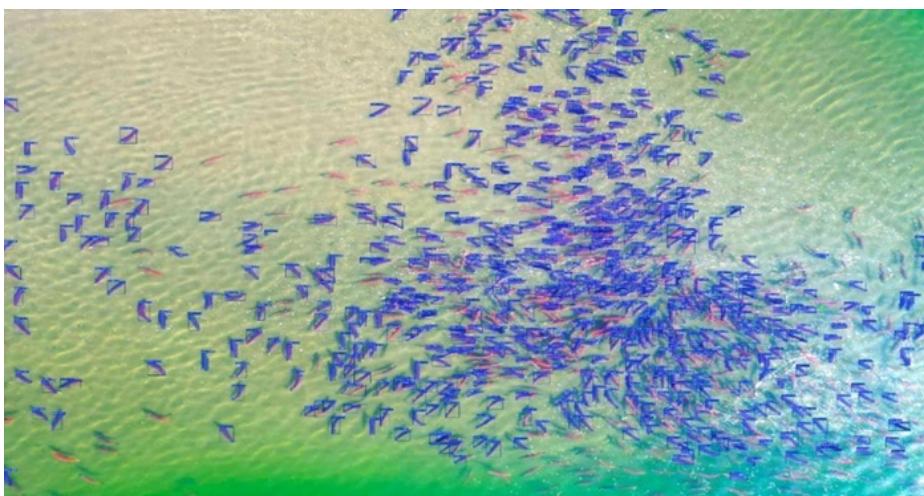


Рис. 7. Счёт производителей нерки методом полигонов.

24%, что значительно превышает аналогичный показатель для метода с ограничивающими рамками.

На основании полученных данных можно сделать вывод, что в текущих условиях метод компьютерного зрения обеспечил баланс между точностью и скоростью обработки изображений, особенно при ограниченном объеме обучающих данных и наличии факторов, искажающих изображение. Вместе с тем, анализ результатов показал, что вариант применения модели с сегментацией объектов требует более обширного набора данных для глубокого обучения, ведь данная модель предна-

значена для повышения точности в сложных условиях, таких как высокая плотность рыб и частичное перекрытие особей. Полигональная разметка рассматривается как перспективное направление для дальнейшей оптимизации модели, особенно при постепенном расширении обучающего набора.

ЗАКЛЮЧЕНИЕ

В результате проведённых исследований удалось доказать высокую эффективность применения метода компьютерного зрения для автоматизации процесса учёта нерки в бассейне оз. Азабачье на аэрофотоснимках,

полученных при помощи БПЛА. Испытание разработанного алгоритма показало, что использование обученной модели компьютерного зрения даже на небольшом наборе исходных данных позволяет достигать точности обнаружения производителей нерки 76–88%, что подтверждает возможность автоматизации процесса мониторинга запаса.

Внедрение компьютерного зрения позволяет существенно оптимизировать процесс подсчёта производителей нерки с фотоматериалов, сокращая временные затраты в сотни раз по сравнению с традиционным ручным методом. Автоматизированная система анализа изображений способна обрабатывать тысячи снимков в час, тогда как эксперт тратит в среднем 3–5 мин на анализ одного изображения.

При этом важно отметить, что система сохраняет все исходные данные для возможной последующей верификации, что обеспечивает контроль качества без значительных временных потерь. Оператор получает возможность сосредоточиться на анализе исключительно спорных случаев, что дополнительно повышает эффективность работы.

Для максимальной эффективности процесса разметки фотографий, полученных с помощью беспилотных летательных аппаратов (БПЛА), критически важно использовать камеру высокого разрешения и производить съёмку с фиксированной высоты.

Для повышения точности и надёжности модели компьютерного зрения необходимо комплексное расширение обучающей выборки, включающее съёмки в различных водоёмах, учёт сезонных изменений, фиксацию различных погодных условий и съёмку с различными состояниями водной поверхности и теней. Использование БПЛА самолётного типа в сочетании с продуманной стратегией сбора данных обеспечит необходимое качество и презентабельность обучающей выборки для создания надёжной системы мониторинга.

СПИСОК ЛИТЕРАТУРЫ

Запорожец О.М., Запорожец Г.В. Использование фото – и видеофиксации для оценки количества производителей тихоокеанских лососей на нерестилищах и путях их миграции: некоторые методические подходы // Исслед. водн. биол. ресурсов Камчатки и сев.-западной части Тихого океана. 2017. Вып. 47. С. 77–90.

Малых К.М., Сошин А.В., Шабуров А.Ю., Коваленко М.Н. Применение искусственной нейросети для учёта рыб на рыбоучётном заграждении // Рыбнохозяйственный комплекс России: 300 лет российской академической науке: II Международная научно-практическая конференция, Москва, 27–28 марта 2024 года. Москва: ФГБНУ «ВНИРО», 2024. С. 205–210.

Малых К.М., Сошин А.В., Коваленко М.Н. Метод количественного учёта производителей нерки р. Озерная на рыбоучётном заграждении с помощью компьютерного зрения // Научные труды Дальрыбвтуза. 2025. Т. 72. № 2. С. 142–153.

Свиридов В.В., Поваров А.Ю. Применение методов искусственного интеллекта для автоматизации беспилотного учёта отнерестившихся особей кеты в Хабаровском крае // Вопр. рыболовства. 2024. Т. 25. № 4. С. 113–124.

Свиридов В.В., Подорожнюк Е.В., Никитин В.Д., Скорик А.В. Модификации беспилотного учёта производителей тихоокеанских лососей в реках Сахалинской области и Хабаровского края // Изв. ТИНРО. 2022. Т. 202. № 4. С. 1015–1031.

Фадеев Е.С., Шевляков Е.А., Фельдман М.Г. Комплексный мониторинг пропуска производителей тихоокеанских лососей р. Камчатка в режиме реального времени // Изв. ТИНРО. 2019. Т. 197. С. 3–20.

Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection // IEEE Conference on Computer Vision and Pattern Recognition. 2015. URL: <https://arxiv.org/pdf/1506.02640.pdf>

Christie K.S., Gilbert S.L., Brown C.L. et al. Unmanned aircraft systems in wildlife research: current and future applications of a transformative

technology // *Frontiers in Ecology and the Environment*. 2016. V. 14. Issue 5. P. 241–251.

Groves P.A., Alcorn B., Wiest M.M. et al. Testing unmanned aircraft systems for salmon spawning surveys // *FACETS*, 2016. V. 1. P. 187–204.

Whitehead K., Hugenholtz C.H., Myshak S. et al. Remote sensing of the environment with small unmanned aircraft systems (UASs), Part 2: scientific and commercial applications // *J.*

of Unmanned Vehicle Systems. 2014. V. 2 (3). 86–102.

Официальный сайт *Ultralytics YOLO* (Электронный ресурс). URL: <https://docs.ultralytics.com/ru>

Wei Wang Advanced Auto Labeling Solution with Added Features // Github repository, 2023 (Электронный ресурс). URL: <https://github.com/CVHub520/X-AnyLabeling>

METHODOLOGICAL ASPECTS OF FISHERY RESEARCH

APPLICATION OF COMPUTER VISION METHODS FOR AERIAL VISUAL ACCOUNTING OF SOCKEYE SALMON PRODUCERS FROM AN UNMANNED AERIAL VEHICLE (UAV) IN THE BASIN OF LAKE AZABACHYE IN 2024

© 2025 y. A.S. Potapov, E.S. Fadeev, K.M. Malykh

*Kamchatka branch of the State Scientific Center of the «VNIRO»,
Russia, Petropavlovsk-Kamchatsky, 683000*

The paper evaluated the effectiveness of computer vision methods for aerial visual accounting of sockeye salmon producers at the key spawning grounds of Lake Azabachye in 2024. The optimal criteria for selecting photo and video materials collected for training a computer vision model are determined.

Keywords: Pacific salmon, sockeye salmon producers, Lake Azabachye, aerial visual accounting, unmanned aerial vehicle (UAV), computer vision, detection model.