

Интернет-журнал «Отходы и ресурсы» <https://resources.today>
Russian Journal of Resources, Conservation and Recycling

2024, Том 11, № 4 / 2024, Vol. 11, Iss. 4 <https://resources.today/issue-4-2024.html>

URL статьи: <https://resources.today/PDF/03INOR424.pdf>

DOI: 10.15862/03INOR424 (<https://doi.org/10.15862/03INOR424>)

2.3.3. Автоматизация и управление технологическими процессами и производствами (технические науки)

Ссылка для цитирования этой статьи:

Рудзейт, О. Ю. Система отслеживания прироста биологической массы бассейна содержания особей рыб / О. Ю. Рудзейт, А. Ф. Артеменко, А. А. Яковенко, Д. С. Мальцева // Отходы и ресурсы. — 2024. — Т. 11. — № 4. — URL: <https://resources.today/PDF/03INOR424.pdf> DOI: 10.15862/03INOR424

For citation:

Rudzeyt O.U., Artemenko A.F., Yakovenko A.A., Maltceva D.S. A system for tracking the increase in the biological mass of the fish keeping pool. *Russian Journal of Resources, Conservation and Recycling*. 2024;11(4): 03INOR424. Available at: <https://resources.today/PDF/03INOR424.pdf>. (In Russ., abstract in Eng.) DOI: 10.15862/03INOR424

Работа выполняется при финансовой поддержке Минобрнауки России в рамках достижения результата федерального проекта «Передовые инженерные школы» (Соглашение № 075-15-2022-1143 от 07 июля 2022 г.)

УДК 004.93'12

Рудзейт Олег Юрьевич

ФГАОУ ВО «Дальневосточный федеральный университет», Владивосток, Россия
Передовая инженерная школа «Институт биотехнологий, биоинженерии и пищевых систем»
Межшкольный научно-образовательный центр «Центр математических методов
народнохозяйственного прогнозирования и программирования»
Ассистент
E-mail: rudzeyt18@mail.ru

Артеменко Александр Федорович

ФГАОУ ВО «Дальневосточный федеральный университет», Владивосток, Россия
Инженер-исследователь лаборатории экспериментальной и трансляционной медицины,
E-mail: artemenko.af@dvfu.ru

Яковенко Андрей Александрович

ФГАОУ ВО «Дальневосточный федеральный университет», Владивосток, Россия
Младший научный сотрудник департамента комплексных проектов
E-mail: iakovenko.aa@dvfu.ru

Мальцева Дана Сергеевна

ФГАОУ ВО «Дальневосточный федеральный университет», Владивосток, Россия
E-mail: maltceva.dser@dvfu.ru

Система отслеживания прироста биологической массы бассейна содержания особей рыб

Аннотация. Оценка объема биомассы рыб в бассейне — одна из наиболее распространённых и актуальных практик в выращивании биологических организмов. Регулярный сбор данных в режиме реального времени о биомассе рыбы требуется исследователям для оптимизации ежедневного кормления, контроля плотности посадки и, определения оптимального времени для сбора биологических образцов. К сожалению, оценить объем биомассы рыбы без человеческого вмешательства достаточно сложно, т. к. рыба свободно перемещается в водной среде, где факторы видимости, освещения и стабильности среды не поддаются контролю. До сих пор распространённым методом оценки биомассы рыбы

в основном является ручной отбор проб, который, как правило, является инвазивным, трудоёмким и занимает много времени. В таком случае необходимо и желательно разработать неинвазивные, быстрые и экономичные методы. Машинное зрение, анализ видеопотока с камер помогают разработать неинвазивные, более быстрые и дешёвые методы для оценки биомассы рыб в бассейне. В этой статье обобщается опыт разработки подобных методов оценки биомассы рыб и представлены их основные концепции и принципы. Анализируются сильные и слабые стороны каждого метода, а также представлены будущие направления исследований. Исследования показывают, что применение информационных технологий, таких как передовые датчики и коммуникационные технологии, имеют большое значение для ускорения разработки новых средств и методов более эффективной оценки биомассы. Основная цель этого исследования заключается в разработке автоматической системы для оценки объема рыбы с использованием машинного зрения, сбора визуальных данных геометрических характеристик рыбы, выделяемых из видеопотока и алгоритмов машинного обучения на примере каскада Хаара.

Однако точность этих методов нуждаются в улучшении, чтобы соответствовать необходимым требованиям аквакультуры.

Ключевые слова: система; обучение; биомасса; данные; машинное зрение; алгоритм; особь

Введение

Оценка количества особей рыбы важна в рециркуляционной системе аквакультуры. Исследователи используют рециркуляционные системы, потому что они могут поддерживать хорошие условия выращивания, такие как контролируемая температура, качество воды и использование корма, в течение всего года. Однако перекармливание или недокармливание в RAS, как основная проблема, по-прежнему влияет на рост и выживаемость популяции. Кроме того, перекармливание влияет на качество воды, что может повысить вероятность заболеваний, а также увеличить производственные затраты из-за нагрузки на механические фильтры, биофильтры и оборудование для насыщения кислородом.

Традиционный способ получения информации о массе рыбы — это отлов и взвешивание. Для получения точных данных необходимо исследовать репрезентативную часть популяции.

Система машинного зрения (MVS) — это неинвазивный метод оценки массы и размера рыбы, который привлекает внимание исследователей на протяжении последних лет. Измерение в резервуаре позволяет избежать стресса и травм. Система стереоскопического зрения стала одной из самых популярных систем для получения различных параметров рыбы, ее количестве и др.

Для измерения поголовья рыбы и ее параметров, а именно длины особи, массы и площади тела рыбы также были изучены различные характеристики изображений. Некоторые алгоритмы, например, комбинация частичного метода наименьших квадратов (PLS) и эллиптического анализа Фурье (EFA) для прогнозирования количества особей, продемонстрировавшая высокую достоверность данных (95 %). Также достоверность вычислений предоставляет гибридная модель CNN в сочетании с оценкой плотности для подсчёта атлантического лосося в глубоководных районах. Точность подсчёта достигла 95,06 % по сравнению с базовой моделью CNN. Основной целью этого исследования является разработка неинвазивного и удалённого автоматического метода отбора проб для оценки количества поголовья семейства осетровых в процессе свободного плавания с использованием системы для мониторинга в реальном времени. Представленная методология

основана на анализе изображений и использует опорное множество Хаара для опознания отдельной особи в бассейне и разметке данных, чтобы в дальнейшем обучить сверточную нейронную сеть, способную определить количество особей в бассейне. Конкретными целями этого исследования были: (1) оценить возможность использования алгоритма Хаара для опознания особи и подготовке разметки для обучения системы; (2) изучить потенциал системы распознавания биологических объектов с применением нейронных алгоритмов. Предполагается, что это быстрый, неинвазивный и недорогой метод получения информации о размерах и массе в процессе выращивания.

Методы и исследования

Исследования в области машинного обучения позволяют приобретать новые знания и реорганизовывать имеющуюся информацию. В процессе обучения моделей, организуемых для поиска и описания взаимосвязи в предоставленном наборе данных, достаточное количество внимания направлено на использование алгоритмов для анализа данных. Как правило в ходе обучения модели используются массивы обучающих данных, чтобы алгоритм мог установить потенциальные закономерности и далее классифицировать или прогнозировать новые данные [1]. Машинное обучение — это область знаний, направленная на решение двух взаимосвязанных задач. Изучая данные и алгоритмы для создания математических моделей, можно увеличить эффективность компьютерных систем [2].

Типы машинного обучения

Машинное обучение включает в себя процессы обучения, направленных на получение «опыта» на основе выборки для выполнения задач. Машинное обучение можно разделить на четыре типа: обучение с учителем, обучение без учителя, обучение с частичным учителем и обучение с подкреплением. Часто используемым методом является обучение с учителем, при котором данные обученной модели имеют соответствующие целевые выборки. Благодаря непрерывному обучению и тренировке на описанных образцах данных и результатах модель может извлекать собственные значения и взаимосвязи, что позволяет осуществлять прогноз результатов на основе новых данных.

Цель состоит в том, чтобы построить краткую модель распределения меток классов на основе признаков-предикторов. При обучении без учителя выбранные выборочные данные не используют какого-либо целевого значения, поэтому отсутствует необходимость проводить анализ влияния этих данных на определённые результаты.

Необходим только анализ внутренних закономерностей этих данных. Обучение без учителя часто применяется в кластерном анализе, а именно в рекомендательных системах, группировке клиентов и сокращении размерности факторов.

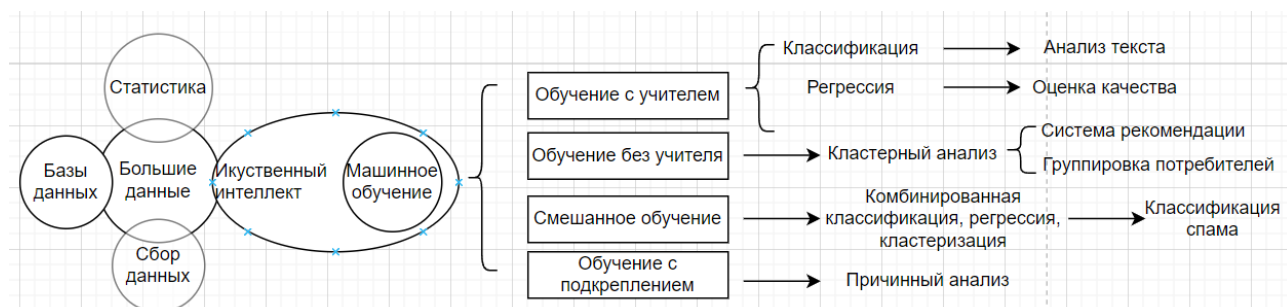


Рисунок 1. Взаимосвязь между типами обучения (разработано авторами)

Комбинированное обучение — это метод, сочетающий обучение с учителем и без. Этот метод позволяет комбинировать классификацию, регрессию и кластеризацию. Обучение с подкреплением — это более сложный метод машинного обучения, который предполагает постоянное взаимодействие между системой и внешними данными. Этот метод преимущественно нацелен на сценарии, где постоянно требуются рассуждения, такие как нейробиология и др. [3]. Рисунок 1 описывает взаимосвязь между четырьмя типами машинного обучения.

Модели машинного обучения

В последние годы технологии машинного обучения стали более глубокими и обширными, а модели машинного обучения применяются во всё большем количестве областей. В этом разделе представлены только модели, применяемые в водной среде.

Дерево решений

Дерево решений — это тип алгоритма, который делит входное пространство на различные области, каждая из которых имеет независимые параметры. В качестве метода индуктивного обучения на основе примеров и модели классификации или регрессии, сформулированной в виде древовидной архитектуры, DT — это процесс, который позволяет извлечь модель классификации в виде дерева из заданного обучающего набора данных. Этот процесс соответствует разделению пространства признаков и построению дерева решений [4].

Каждый нелистовой узел в дереве записывает характеристики категории суждения, а каждый листовой узел представляет категорию окончательного суждения. Корневой узел и каждый конечный узел образуют классифицированное правило пути. При тестировании нового образца нужно только начать с корневого узла и последовательно тестировать каждый узел ответвления, затем рекурсивно переходить в поддерево по соответствующему ответвлению для повторного тестирования, пока не будет достигнут конечный узел [5].

Байесовский алгоритм (NB)

Байесовский алгоритм основан на байесовском принципе, посредством которого знание вероятностной статистики используется для классификации выборочных наборов данных. Данный алгоритм представляет собой простой, но очень мощный алгоритм моделирования прогнозирования и является одним из наиболее широко используемых алгоритмов классификации, который упрощен на основе байесовского алгоритма. В данном случае предполагается, что атрибуты условно независимы друг от друга при заданных целевых значениях [6].

Метод опорных векторов (SVM)

Метод опорных векторов (SVM) — это репрезентативный алгоритм в области статистического обучения, который, однако, отличается от традиционного метода мышления. SVM — один из наиболее распространённых алгоритмов с учителем, используемых для решения задач классификации по двум группам. Это достигается за счёт увеличения размерности входного пространства признаков для упрощения и сокращения задачи, тем самым превращая её в классическую задачу с линейной делимостью [7].

Искусственная нейронная сеть (ИНС)

Искусственная нейронная сеть (ИНС) основана на базовом принципе нейронных сетей в биологии и может быть разделена на традиционные и глубокие формы [8].

Модель состоит из множества взаимосвязанных узлов, и каждый узел представляет собой определённую выходную функцию, называемую функцией активации, а связь между каждыми двумя узлами представляет собой взвешенное значение сигнала, проходящего через эту связь, и называется весом.

Узлы расположены в несколько слоёв, которые делятся на входной слой, скрытый слой и выходной слой (рис. 2).




Рисунок 2. Описание нейронной сети¹

Алгоритм k ближайших соседей (KNN)

Алгоритм k ближайших соседей (KNN) — один из самых простых методов среди алгоритмов классификации. В этом случае образец считается наиболее похожим на k ближайших образцов в наборе данных, и если большинство из этих k образцов относятся к определённой категории, то и образец относится к этой категории.

Затем образец классифицируется путём измерения расстояния между различными значениями собственных векторов. Метод KNN подходит для небольшого объёма данных с низкой точностью из-за большого количества вычислений [9].

Метод KNN также подходит для наборов данных с большим количеством пересечений или совпадений классов.

Краткое описание моделей

У разных моделей машинного обучения есть свои преимущества и недостатки в применении (табл. 1). Поэтому очень важно выбрать оптимальный алгоритм в соответствии с характеристиками модели и конкретными задачами.

¹ https://proproprogs.ru/neural_network/struktura-i-princip-raboty-polnosvyaznyh-neyronnyh-setey.

Таблица 1

Краткое описание каждой модели машинного обучения

	DT	NB	SVM	ANN	KNN
Разница	1. Определяет данные по собственным значениям 2. Двоичное деление	1. Предполагается, что признаки независимы друг от друга 2. Используется условная вероятность	1. Создается линейно разделяющая гиперплоскость 2. Данные отображаются на многомерном пространстве	1. Состоит из входного слоя, скрытого слоя и выходного слоя 2. Модель имеет внутреннюю взаимосвязь с помощью весовых коэффициентов	Производит деление по большинству категорий в K образцах, ближайших к точке отбора проб
Преимущества	1. Низкая вычислительная сложность 2. Простое понимание результатов	1. Эффективен при меньшем объеме данных 2. Решает проблемы из разных категорий	1. Низкая частота ошибок обобщения 2. Низкая вычислительная нагрузка	1. Обладает функцией самообучения 2. Обладает мощной функцией параллельной и распределенной обработки	1. Высокая точность 2. Не чувствителен к выбросам
Недостатки	1. Чувствителен к отсутствующим данным 2. Может привести к переобучению	1. Чувствителен к способу подготовки входных данных 2. Необходимо знать априорную вероятность	1. Чувствителен к настройке параметров и выбору функции ядра 2. Чувствителен к отсутствующим данным	1. Требуется много параметров 2. Большие временные затраты на работу алгоритма	1. Высокая вычислительная сложность 2. Высокая пространственная сложность
Общий алгоритм	CART, C4.5	NBM	SVR, LSSVM и т. д.	BP, CNN и др.	KNN

Разработано авторами

Оценка метода анализа биомассы

В статье был предложен метод оценки количества рыбы на основе опорных множеств Хаара и нейронной сети [10]. Общий процесс применения метода показан на рисунке 3.

1. Коллекция изображений рыб. Была создана экспериментальная платформа для сбора данных для оценки массы рыб, затем были собраны изображения рыб, чтобы сформировать экспериментальный набор данных.
2. Предварительная обработка изображения рыбы. Была произведена сегментация изображения для уменьшения количества посторонних объектов в кадре. Затем на основе результатов сегментации были выполнены другие операции предварительной обработки, такие как улучшение и бинаризация изображения, для извлечения контура тела рыбы.
3. Извлечение и расчёт характеристик изображений рыб. Были извлечены характеристики формы изображений рыб. Кроме того, для расчёта значений характеристик изображений рыб был использован каскадный метод Хаара для разметки изображений перед обучением нейросетевого алгоритма [11].
4. Оценка количества особей. Для построения модели оценки массы рыбы был использован алгоритм ANN, а затем модель была протестирована на тестовом наборе данных для определения количества рыбы.

В качестве экспериментального объекта в этой статье было взято поголовье осетровых. Изображения рыбы были взяты из видеопотока с видом сверху были сделаны цифровой однообъективной камерой. Изображения осетровых, полученные в ходе эксперимента, являются цветными изображениями RGB. Разрешение этих изображений составляет 1 920×1 080 пикселей, а формат — jpg. Всего было собрано 6 000 изображений.

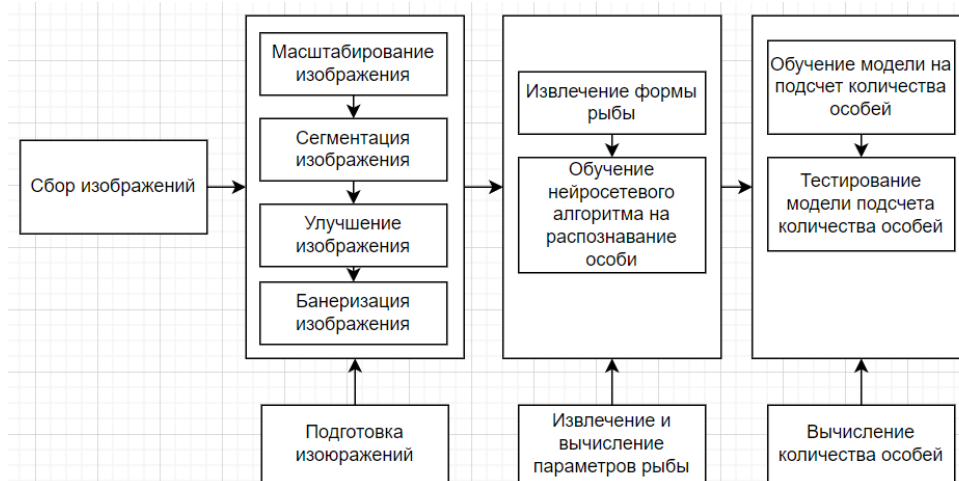


Рисунок 3. Описание метода анализа (разработано авторами)

Масштабирование изображения. Снимки рыб, сделанные камерой с высоким разрешением, не подходят для алгоритмов обработки изображений большого масштаба. Поэтому для ускорения обработки изображений функция масштабирования изображений в OpenCV была использована для уменьшения размеров снимков рыб до 720×480 пикселей [12].

Кадрирование изображения. Чтобы исключить захват посторонних объектов и уменьшить количество шумов изображение с камеры было кадрировано. Это позволяет повысить точность распознавания в будущем, исключая попытки ошибочного распознавания образов.

Улучшение изображения. При изменении шкалы серого на изображении рыбы повышается контрастность изображения, выделяется важная информация, ненужная информация устраняется или ослабляется, а контур целевой рыбы улучшается. Изображения рыбы были улучшены с помощью заливки перехода от формата изображения RGB к оттенкам серого с использованием OpenCV.

Бинаризация изображения. При бинаризации всё изображение рыбы представляется в двух цветах, чёрном и белом, сохраняя более важную морфологическую информацию. Для бинаризации изображений рыбы без ручной установки порога использовался глобальный адаптивный порог.




Рисунок 4. Результат работы метода Хаара (разработано авторами)

Разметка изображения. В дальнейшем была произведена разметка изображения отдельных особей на фотографии с помощью каскадного метода Хаара [14], позволяющего выделить требуемый объект и наложить на фотографию контур, в который заключен объект для работы нейросетевого алгоритма (рис. 4).

В последние годы внимание постепенно смещается в сторону обнаружения рыб с помощью модели CNN. Было принято решение использовать алгоритм на основе одного из самых популярных одноэтапных фреймворков для обнаружения целей был использован метод You Only Look Once (YOLO).

Характеристики нейронной сети

Для распознавания особей была адаптирована модель YOLOv5s, чтобы повысить скорость извлечения признаков. После создания модели из полученного набора данных была произведена оценка корректности работы алгоритма и точности распознавания количества особей в резервуаре [15]. Результаты подтвердили, что модель может обеспечить высокую точность обнаружения рыбы по сравнению с другими нейросетевыми алгоритмами и достигли показателя в 95,4 %.

Архитектура нейронной сети.

«Скелет»: YOLOv5s использует CSPDarknet53 в качестве скелета. CSP (Cross Stage Partial) архитектура помогает уменьшить количество вычислений и увеличить скорость модели без потери в точности. Она делит поток данных на две части и комбинирует их позже, что улучшает извлечение признаков.

«Шея»: в качестве шеи используется PANet (Path Aggregation Network), которая помогает в улучшении передачи информации между различными уровнями пирамиды признаков. Это улучшает детекцию объектов разных размеров за счет агрегации признаков с разных уровней.

«Голова»: голова модели включает в себя несколько выходных слоев для предсказания координат объектов, их размеров, вероятностей классов и уверенности в детекции. Она использует якорные механизмы для определения положений и размеров объектов.

Описание гиперпараметров для обучения модели нейронной сети

Модель и приёмы:

- Использована модель YOLOv5s с блоком сегментации.
- Использован набор приёмов HSV_Aug и Mosaic.

Цветовое дополнение HSV (HSV_Aug):

- Оттенок (H): 0,015.
- Насыщенность (S): 0,7.
- Яркость (V): 0,4.

Мозаичное увеличение (Mosaic): Включено с параметром 1.

Размер входного изображения: 640×640 пикселей.

Продолжительность обучения: 300 эпох.

Оптимизатор и скорость обучения:

- Оптимизатор: стохастический градиентный спуск (SGD).
- Начальная скорость обучения: 0,0015.

Набор данных и размер пакета:

- Используется пользовательский набор данных.
- Batch size: 2.

Улучшение данных для обнаружения объектов

Для улучшения данных в задаче обнаружения объектов с использованием YOLOv5, каждая партия данных проходит через загрузчик, который применяет различные методы аугментации. Эти методы включают масштабирование, корректировку цветового пространства и мозаичное улучшение, что помогает повысить разнообразие и обогащение обучающего набора. В рамках данной задачи по обучению модели YOLOv5 для обнаружения объектов аквакультуры, были применены такие техники аугментации, как Mosaic (мозаичное слияние нескольких изображений) и HSV_Aug (регулировка оттенка, насыщенности и яркости) [16].

Методы обнаружения и оценки

Основной подход состоит из нескольких ключевых этапов.

1. Использование сети YOLOv5 в качестве базовой архитектуры для обнаружения объектов, что обеспечивает надежную и быструю идентификацию объектов.
2. Интеграция модуля семантической сегментации в YOLOv5, что позволяет модели не только обнаруживать, но и сегментировать объекты на уровне пикселей.
3. Для оптимизации производительности сегментации используется модуль Ghost, который помогает уменьшить вычислительную нагрузку и повысить эффективность сегментации. Это достигается за счет генерации более легких и быстрых признаков без значительной потери точности.
4. Замена стандартной функции активации на HardSwish позволяет улучшить способность обучаться более сложным зависимостям и повысить общую точность и эффективность сети.

Итоговая точность обнаружения объектов: 0,954, recall — 0,930, а скорость — 116,6 кадров в секунду на видеоадаптере Nvidia RTX3060 (табл. 2).

Таблица 2

Результат оптимизации работы модели

Группа	Precision	Recall	F1-мера	mAP@0:5	FPS
YOLOv5s+модуль сегментации C3	0.954	0.917	0.935	0.976	115.1
YOLOv5s+модуль сегментации GhostC3	0.952	0.927	0.939	0.975	116.1
YOLOv5s+модуль сегментации GhostC3 + HardSwish	0.954	0.930	0.942	0.976	116.6

Разработано авторами

Заключение

В данной статье представлен обзор и анализ развития машинного обучения в интеллектуальной аквакультуре рыб, а также краткое описание методов применения машинного обучения.

Развитие нейронных сетей расширило возможности интеллектуального применения в аквакультуре рыб и повысило эффективность исследований. Как бы то ни было, в использовании технологий машинного обучения остаётся несколько недостатков, таких как сложность и неполнота наборов данных, низкое качество изображений, отсутствие данных и высокие затраты на техническую реализацию. Неопределённость уникальных факторов, в том числе способа производства, климатических условий, географического положения, местной окружающей среды и биологического состава аквакультурных сред, ограничивает применение машинного обучения в аквакультуре. Кроме того, для сбора данных и реализации алгоритмов требуются аппаратные средства.

Тем не менее, технология машинного обучения по-прежнему обеспечивает относительно эффективные технические методы для аквакультуры в области обработки данных, извлечения информации, мониторинга в реальном времени. В будущем развитие рыболовства будет связано с технологией машинного обучения, которая остаётся новой и развивающейся областью и, в конечном итоге, получит широкое распространение в аквакультуре.

Также был представлен анализ метода оценки хвостов рыбы в бассейне на основе методов Хаара и нейронной сети, который имеет большое значение для определения точного количества рыбы на разных стадиях роста в бассейне, повышая эффективность разведения. Представленная система может точно, неинвазивно и дистанционно определять массу рыбы. Метод поддерживает множество интеллектуальных терминалов в качестве устройств для получения изображений, но не требует фиксации расстояния между устройством для получения изображений и целевой рыбой. Кроме того, оценка показывает, что система на основе изображения спинной части рыбы обладает хорошим потенциалом для оценки количества особей. Предложенный способ получения изображений практичен и применим в реальных условиях аквакультуры, а также является простым и точным для рыбоводов и исследователей, чтобы точно и непрерывно отслеживать скорость роста рыбы в резервуарах.

ЛИТЕРАТУРА

1. Li D., Hao Y., Duan Y. Nonintrusive methods for biomass estimation in aquaculture with emphasis on fish: a review // *Reviews in Aquaculture*. 2020. V. 3. N. 12. P. 1390–1411.
2. Puig-Pons V., Muñoz-Benavent P., Espinosa V., Andreu-García G., Valiente-González J.M., Estruch V.D., Ordóñez P., Pérez-Arjonaa I., Atienزاب V., Mèliche B., de la Gándarad F., Santaellad E. Automatic Bluefin Tuna (*Thunnus thynnus*) biomass estimation during transfers using acoustic and computer vision techniques // *Aquacultural Engineering*. 2019. N. 85. P. 22–31.
3. Tengtrairat N., Woo W.L., Parathai P., Rinchumphu D., Chaichana C. Non-Intrusive Fish Weight Estimation in Turbid Water Using Deep Learning and Regression Models. *Sensors*, 2022, vol. 14, no. 22, p. 5161.
4. Savinov E., Ivashko E. Automatic contactless weighing of fish during experiments. *Ivannikov Ispras Open Conference (ISPEAS)*. 2021. Pp. 134–139.
5. Risholm P., Mohammed A., Kirkhus T., Clausen S., Vasilyev L., Folkedal O., Johnsen O., Haugholt K.H., Thielemann J. Automatic length estimation of free-swimming fish using an underwater 3D range-gated camera. *Aquacultural Engineering*, 2022, no. 97(3), p. 102227.

6. Ubina N., Cheng S.C., Chang C.C., Chen H.Y. Evaluating fish feeding intensity in aquaculture with convolutional neural networks // *Aquacultural Engineering*. 2021. N. 94(8). P. 102178.
7. Hao Y., Yin H., Li D. A novel method of fish tail fin removal for mass estimation using computer vision // *Computers and Electronics in Agriculture*. 2022. N. 193. DOI: <https://doi.org/10.1016/j.compag.2021.106601>.
8. Zhao, Z.; Liu, Y.; Sun, X.; Liu, J.; Yang, X.; Zhou, C. Composited FishNet: Fish Detection and Species Recognition from Low-Quality Underwater Videos. *IEEE Trans. Image Process*. 2021, 30, 4719–4734.
9. Wang, Z.; Liu, H.; Zhang, G.; Yang, X.; Wen, L.; Zhao, W. Diseased fish detection in the underwater environment using an improved yolov5 network for intensive aquaculture. *Fishes* 2023, 8, 169.
10. Zhu, L.; Wang, X.; Ke, Z.; Zhang, W.; Lau, R.W. Biformer: Vision Transformer with Bi-Level Routing Attention. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver, BC, Canada, 17–24 June 2023*; pp. 10323–10333.
11. Gadamsetty, S.; Ch, R.; Ch, A.; Iwendi, C.; Gadekallu, T.R. Hash-Based Deep Learning Approach for Remote Sensing Satellite Imagery Detection. *Water* 2022, 14, 707.
12. Gong, B., Ergu, D., Cai, Y., & Ma, B. (2020). A Method for Wheat Head Detection Based on YOLO V4.
13. Ouis, Mohammed & Akhloufi, Moulay. (2023). YOLO-Based Fish Detection in Underwater Environments. 44. 10.3390/ECRS2023-16315.
14. Sirisha U., Praveen S.P., Srinivasu P.N., Barsocchi P., Bhoi A.K. 2023. Statistical analysis of design aspects of various YOLO-based deep learning models for object detection. *International Journal of Computational Intelligence Systems* 16(1):126.
15. Patro K.S.K., Yadav V.K., Bharti V.S., Sharma A., Sharma A. 2023. Fish detection in underwater environments using deep learning. *National Academy Science Letters* 46:407–412.
16. Liu Q., Gong X., Li J., Wang H., Liu R., Liu D., Zhou R., Xie T., Fu R., Duan X. 2023. A multitask model for realtime fish detection and segmentation based on YOLOv5. *PeerJ Computer Science* 9: e1262 DOI: <https://doi.org/10.7717/peerj-cs.1262>.

Rudzeyt Oleg Urievich

Far Eastern Federal University, Vladivostok, Russia
Advanced Engineering School «Institute of Biotechnology, Bioengineering and Food Systems»
Interschool Scientific and Educational Center «Center for Mathematical Methods
of National Economic Forecasting and Programming»
E-mail: rudzeyt18@mail.ru

Artemenko Alexander Fedorovich

Far Eastern Federal University, Vladivostok, Russia
E-mail: artemenko.af@dvfu.ru

Yakovenko Andrey Alexandrovich

Far Eastern Federal University, Vladivostok, Russia
E-mail: iakovenko.aa@dvfu.ru

Maltceva Dana Sergeevna

Far Eastern Federal University, Vladivostok, Russia
E-mail: maltceva.dser@dvfu.ru

A system for tracking the increase in the biological mass of the fish keeping pool

Abstract. Estimating the biomass volume of fish in a pond is one of the most common and relevant practices in the cultivation of biological organisms. Regular real-time data collection on fish biomass is required by researchers to optimize daily feeding, control stocking density, and determine the optimal time for collecting biological samples. Unfortunately, assessing fish biomass volume without human intervention is quite challenging, as fish move freely in an aquatic environment where visibility, lighting, and environmental stability factors are beyond control. To date, the most common method for assessing fish biomass has primarily been manual sampling, which is typically invasive, labor-intensive, and time-consuming. In this context, it is necessary and desirable to develop non-invasive, fast, and economical methods. Machine vision and video stream analysis from cameras help develop non-invasive, faster, and cheaper methods for assessing fish biomass in ponds. This article summarizes the experience of developing such methods for assessing fish biomass and presents their main concepts and principles. The strengths and weaknesses of each method are analyzed, and future research directions are presented. Research shows that the application of information technologies, such as advanced sensors and communication technologies, plays a significant role in accelerating the development of new tools and methods for more effective biomass assessment. The main goal of this study was to develop an automatic system for assessing fish volume using machine vision, collecting visual data on the geometric characteristics of fish extracted from the video stream, and machine learning algorithms exemplified by the Haar cascade. However, the accuracy of these methods still needs improvement to meet the requirements of intensive aquaculture.

Keywords: system; training; biomass; data; machine vision; algorithm; individual