

Нейросетевой алгоритм на основе YOLOv8 для обнаружения биообъектов на примере *Daphnia magna*

© 2025. А. С. Олькова, д. б. н., доцент,
Е. В. Медведева, д. т. н., доцент,
Вятский государственный университет,
610000, Россия, г. Киров, ул. Московская, д. 36,
e-mail: usr08617@vyatsu.ru

Автоматизация рутинных процедур биологических анализов является важной междисциплинарной задачей. В статье описан нейросетевой алгоритм для обнаружения биологических объектов мезоразмера. Биомоделью служили ракообразные *Daphnia magna*, часто используемые для биотестирования природных и техногенных сред. Алгоритм реализован на легковесной свёрточной нейронной сети (СНС) YOLOv8s. Для обучения и тестирования СНС использовались собственные фото- и видеоизображения *D. magna*, а также находящиеся в открытом доступе на платформах Roboflow и Kaggle. База изображений была представлена 12540 снимками, из которых 430 исходных, остальные – преобразованные с помощью функций сервиса Roboflow. Обучение проводилось в течение 150 эпох, при разрешении изображений 1280×1280 пикселей. С помощью встроенных функций «Object Tracking» и «Object Counting» реализованы процедуры подсчёта и отслеживания объектов. Алгоритм обнаруживает объекты на статических изображениях и на видео в режиме реального времени. Значения метрик оценки качества работы алгоритма: средняя точность – 89,8%; точность – 88,4%; полнота – 87,4%. Алгоритм направлен на снижение трудоёмкости методов биотестирования и повышения точности результатов обработки данных. Предложенный нейросетевой алгоритм обнаружения биообъектов может быть адаптирован через аналогичное обучение к поиску и подсчёту других живых организмов.

Ключевые слова: свёрточная нейронная сеть, YOLO, алгоритм обнаружения, *Daphnia magna*, биотестирование.

YOLOv8-based neural network algorithm for detecting biological objects: *Daphnia magna* case study

© 2025. A. S. Olkova ^{ORCID: 0000-0002-5798-8211}
E. V. Medvedeva ^{ORCID: 0000-0002-0677-1418}
Vyatka State University,
36, Moskovskaya St., Kirov, Russia, 610000,
e-mail: usr08617@vyatsu.ru

Automation of routine biological analysis procedures is an important interdisciplinary issue. The article describes a neural network algorithm for detecting meso-sized biological objects. The biomodel was *Daphnia magna*, which is frequent for bioassaying of natural and man-made environments. The algorithm is implemented on YOLOv8s lightweight convolutional neural network (CNN). *Daphnia magna*'s original photo and video images as well as those publicly available on the Roboflow and Kaggle platforms were used for CNN training and testing. The image database consisted of 12540 images, of which 430 were original, the rest were transformed using the functions of the Roboflow service. The training was conducted over 150 epochs, with an image resolution of 1280×1280 pixels. Procedures for counting and tracking objects are implemented using the built-in functions "Object Tracking" and "Object Counting". The algorithm detects objects in static images and videos in real time. The processing speed of video images was about 50 ms per frame, which is enough for the algorithm to work in real time. The values of the algorithm quality rating metrics were the following: mAP – 89.8%; precision – 88.4%; recall – 87.4%. The main mistake of the neural network was counting the reflections of the same daphnia on the inner and outer surfaces of the aquarium glass. The algorithm is aimed at reducing the complexity of biotesting methods and increasing the accuracy of data processing results. The proposed neural network algorithm for detecting biological objects can be adapted through similar training to the search and counting of other organisms.

Keywords: convolutional neural network, YOLO, detection algorithm, *Daphnia magna*, bioassay.

Биологический мониторинг и биотестирование как группы методов оценки качества окружающей среды в целом и её компонентов остро нуждаются в автоматизации составляющих их процессов [1]. Например, на визуальный подсчёт низших ракообразных *Daphnia magna* Straus для определения острой токсичности требуется в среднем 15 мин на одну пробу, представленную тремя повторностями. Всего лишь на 10 проб исполнитель потратит 10 ч непрерывных наблюдений в течение четырёх рабочих дней. Более информативный показатель – плодовитость особей – требует подобных наблюдений в течение 21 сут. Реализация многих биоиндикационных методик осложняется высокими требованиями к квалификации исполнителя. Так, идентификация одного биологического вида планктонных ракообразных в составе биопробы учёным, имеющим опыт работы более 20 лет, может занимать до одного часа.

Одним из фронтальных направлений распознавания биологических объектов, идентификации их систематической принадлежности и определения морфофункциональных характеристик является использование нейросетей – программ, алгоритмы которых имитируют взаимодействие мозговых нейронов, за счёт чего происходит машинное обучение [2, 3].

Развитие подобных программ в биодиагностике начиналось со способов улучшения изображений: контраст уровня серого цвета, преобразование изображения в цветовую модель, состоящую из трёх каналов (RGB) [4, 5]. Более передовым подходом стали технологии глубокого обучения с использованием свёрточных нейронных сетей (СНС). Так, при разделении трёх видов окрашенных бактерий *Bacillus coagulans*, *Staphylococcus aureus* и *Clostridium perfringens* точность обучения и тестирования была 96,75% и 81,35% соответственно [6]. В работе [7] была предложена усовершенствованная свёрточная нейронная сеть U-Net (LCU-Net) для задачи мультиклассовой сегментации многомасштабных изображений микроорганизмов. Алгоритм LCU-Net позволил улучшить результаты сегментации и уменьшить требуемую память с 355 до 103 МБ. Оценки качества результатов сегментации с помощью LCU-Net по метрикам Dice, Jaccard, Precision, Recall, Accuracy и VOE равны 87,13%; 79,74%; 90,14%; 87,12%; 96,91% и 20,26%, соответственно.

Алгоритмы, связанные с обнаружением (распознаванием, классификацией, сегмен-

тацией) объектов на изображениях, различаются точностью, скоростью работы и затрачиваемыми вычислительными ресурсами [8–10]. Результаты работы алгоритмов зависят от выбора оптимальной архитектуры СНС, подготовки набора данных для обучения сети, настройки гиперпараметров сети.

Применение СНС для эколого-биологических задач позволит снизить трудоёмкость и временные затраты на их проведение, повысить точность подсчёта параметров биологических объектов, уменьшить влияние человеческого фактора на качество исследований.

Цель данной работы заключалась в разработке нейросетевого алгоритма обнаружения и подсчёта особей *D. magna*, зафиксированных на статических изображениях и видео.

Объекты и методы исследования

Объектом исследования была маточная культура *D. magna*, состоящая из разновозрастных особей, а также ёмкости с пробами, тестируемыми на хроническую токсичность по плодовитости дафний. В тестируемых пробах было две возрастные группы рачков: взрослые партеногенетические самки (возраст 15 дней), ювенильные особи (возраст 1–2 дня).

Для реализации алгоритма обнаружения и подсчёта *D. magna* на видеоизображениях в режиме реального времени была выбрана облегчённая модель СНС YOLOv8s. Для её обучения и тестирования использовались собственные изображения *D. magna* и находящиеся в открытом доступе на платформах искусственного интеллекта Roboflow [11] и Kaggle [12]. Обучение проводилось в среде разработки Google Colab на графическом ускорителе GPU A100.

Для оценки точности работы алгоритмов использовались метрики: средняя точность (AP), интерполированная средняя точность (mAP), точность (precision) и полнота (recall). Метрика mAP является основной и используется для оценки производительности СНС, вычисляя средние значения AP по нескольким классам объектов. Метрика точность количественно определяет долю истинных положительных результатов среди всех положительных предсказаний, оценивая способность модели избегать ложных определений. Метрика полнота рассчитывает долю истинных положительных прогнозов среди всех реальных, оценивая способность СНС обнаруживать все объекты класса.

Результаты и обсуждение

Алгоритм обнаружения биообъектов на основе СНС YOLOv8s. Алгоритм обнаружения состоит из нескольких этапов: подготовки входных данных, обучения и тестирования СНС на сформированном наборе данных, проверки результатов на неразмеченном наборе данных.

Начальный набор данных биообъектов *Daphnia magna* состоял из 430 размеченных изображений. Для повышения точности обучения СНС набор данных был увеличен до 12540. Увеличение данных выполнялось с помощью функций сервиса Roboflow: масштабирования, вращения изображений и наложения эффектов, таких как импульсный шум, изменения яркости, размытия и др. Весь набор данных разбивался на тренировочные и тестовые изображения. Примеры размеченных изображений дафний, которые использовались для обучения модели YOLOv8s, показаны на рисунке 1.

Подготовленные размеченные изображения дафний использовались для обучения СНС. Обучение проводилось в течение 150 эпох, при разрешении изображений 1280×1280 пикселей. На рисунке 2 представлены зависимости метрик точности, полноты и средней точности mAP от числа эпох.

На приведённых графиках видно, что обучение модели YOLOv8s замедляется после 70 эпохи, значения метрик при этом достигают

значений: точность – 88,4%; полнота – 87,4%; средняя точность – 89,8%. При обработке видеоизображений скорость модели составила около 50 мс/кадр, что достаточно для работы алгоритма в режиме реального времени. Следовательно, выбранная облегчённая модель СНС YOLOv8s позволила добиться хороших соотношений по точности обнаружения и скорости работы по сравнению с сетями других архитектур, например, таких как SSD [13], R-CNN [14], а также YOLO более ранних версий [10].

Алгоритм обнаружения объектов был дополнен функциями подсчёта количества обнаруженных объектов (Object Counting) и отслеживания объектов на видеоизображении (Object tracking), встроенными в фреймворк Ultralytics. Функция Object tracking позволяет определять координаты движущегося объекта (или нескольких объектов) в кадре. Каждому объекту присваивается свой идентификационный номер. Эта функция может использоваться, например, для оценки скорости и ускорения движения дафний, помещённых в среды с разными свойствами, в том числе токсическими.

Результаты обнаружения *D. magna* нейросетью. Тестирование алгоритма проводилось на неразмеченном тестовом наборе. На рисунке 3 (см. цв. вкладку I) показан пример обнаружения маточных культур *D. magna*. Обнаруженные особи выделялись прямоугольной рамкой.

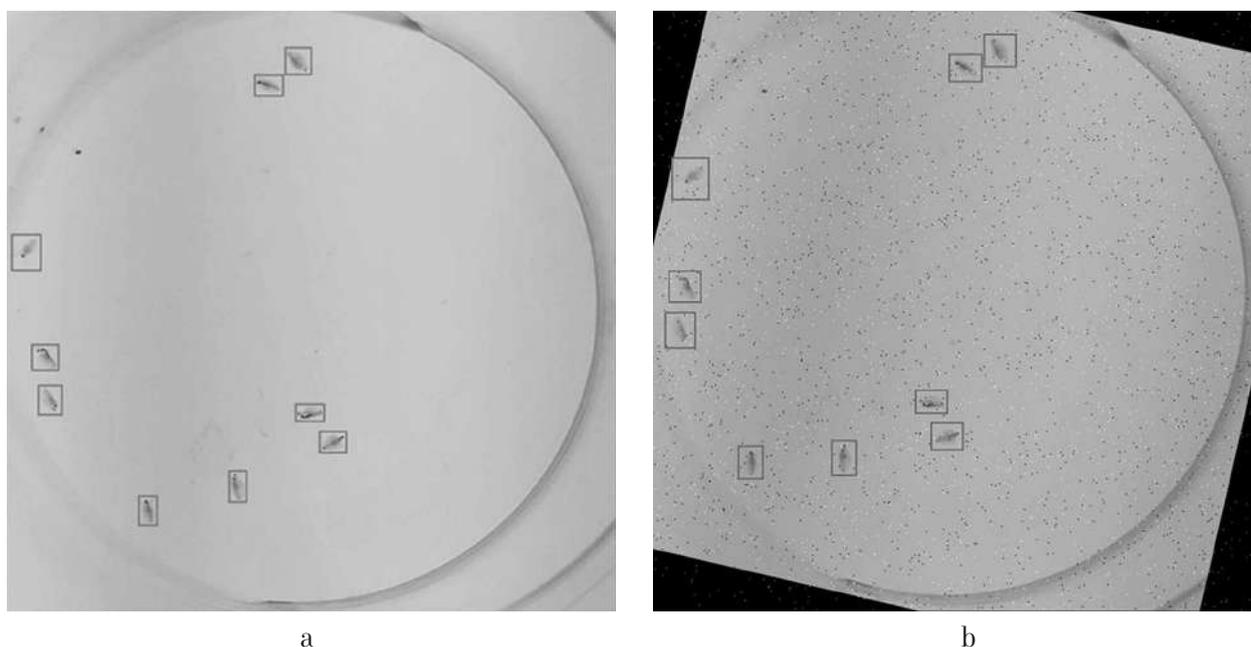


Рис. 1. Примеры размеченных изображений дафний: а – исходное изображение, б – с добавлением визуальных шумов, размытием и поворотом на 15°. Рамкой программа указывает на искомые объекты
Fig. 1. Examples of *Daphnia* images with markings: а – original image, б – with added noise, blurring and rotation by 15°. The program highlights the desired objects with a frame

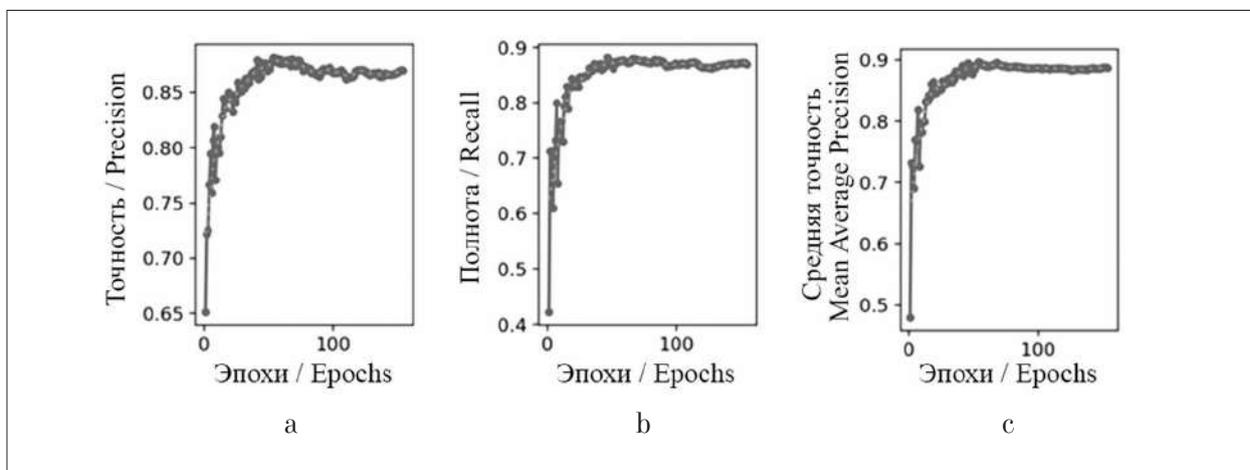


Рис. 2. Зависимости точности (а), полноты (b) и средней точности (с) от числа эпох
Fig. 2. Precision (a), recall (b), and mean average precision (c) dependence on the number of epochs

В культивационной ёмкости (рис. 3а) находилось 11 особей *D. magna* разного возраста и, соответственно, размера. Обученная нейросеть YOLOv8s обнаружила 13 рачков, 2 из которых были ошибками, а именно – отражениями одной и той же дафнии на внутренней и внешней поверхности стекла. В результате нейросеть допустила 2 системные ошибки. На втором изображении модель «пропустила» только 2 объекта, 75 – обнаружила.

Далее была смоделирована ситуация биотеста на определение хронической токсичности, когда в относительно небольшой ёмкости (химический стакан, 100 мл воды) одновременно находятся взрослые особи и народившаяся молодь. На рисунке 4а (см. цв. вкладку I) приведено исходное изображение химического стакана с находящимися в нём одной взрослой особью и четырьмя ювенильными. Обнаружение всех особей показано на рисунке 4b (см. цв. вкладку I). Количество народившейся молодежи определяется как разность числа обнаруженных особей и взрослых особей, помещённых в стакан в начале эксперимента. Впоследствии операцию можно сделать автоматической.

Алгоритм показал 100%-й результат. Таким образом, достигнутые нами результаты не уступают актуальным опубликованным данным. Например, известно о средней точности обнаружения взрослых особей *D. magna* 99,72% и 98,30% для молодежи [15].

На рисунке 5 (см. цв. вкладку I) приведены примеры двух кадров видео с дафниями в резервуаре (аквариуме), на которых протестирован алгоритм обнаружения объектов с функциями их отслеживания и подсчёта.

На рисунке 5 показано, что каждый обнаруженный объект выделяется рамкой, ему присваивается случайным образом идентификационный номер, который за ним сохраняется в последующих кадрах. Кроме того, для каждой особи визуализируется траектория её движения на протяжении нескольких кадров. Свёрточная нейронная сеть YOLO преодолела помехи распознавания под водой, как было сообщено ещё для версии v7 [16]. В итоге, точность обнаружения составила 93%. Известны варианты повышения эффективности извлечения признаков, совместимые с YOLO, например, внедрение деформируемой свёрточной сети DCNv3 и использование слоя C2f_DCNv3 [17].

Безусловно, требуется дополнительное программное обеспечение, чтобы усилить возможности нейросетей в области биотестирования. В частности, необходимо «научить» нейросеть различать взрослых самок и молодь, появляющуюся в процессе эксперимента; учитывать смертность особей по количеству иммобилизованных особей; вычленять поведенческие нарушения. Такие работы уже проводятся [18], обученная нейросеть оценивала частоту сердечных сокращений *D. magna* для последующего анализа потенциальной кардиотоксичности веществ. В свою очередь, появление таких алгоритмов потребует пересмотра методик биотестирования.

Нейросети с лёгкостью встраиваются в работу по обнаружению однотипных объектов, например, подсчёту икры камышового жука *Epidalea calamita* [19], обнаружению следов исчезающих видов на снимках [20], что в настоящее время осуществляется специалистами визуально.

А. С. Олькова, Е. В. Медведева «Нейросетевой алгоритм на основе YOLOv8 для обнаружения биообъектов на примере *Daphnia magna*». С. 19.

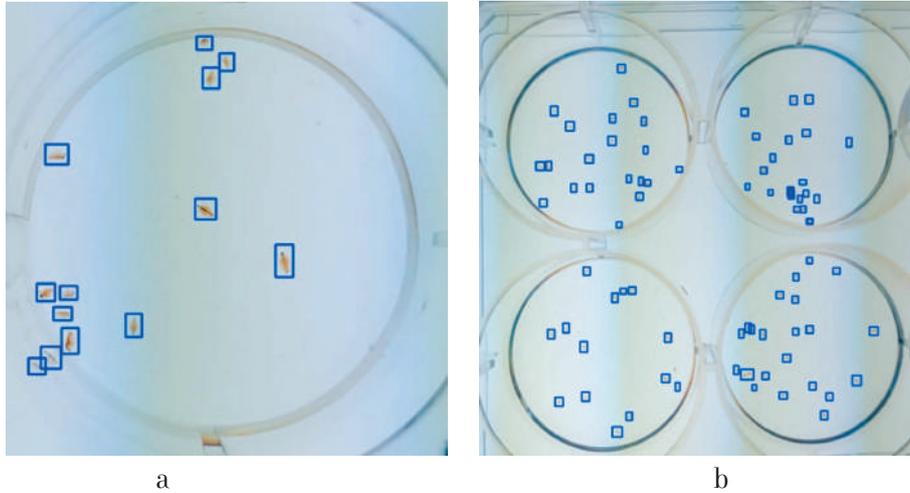


Рис. 3. Пример обнаружения особей *D. magna* в одиночных ёмкостях (а), в нескольких ёмкостях (б)
Fig. 3. The detection of *D. magna* individuals in single containers (a), in several containers (b)

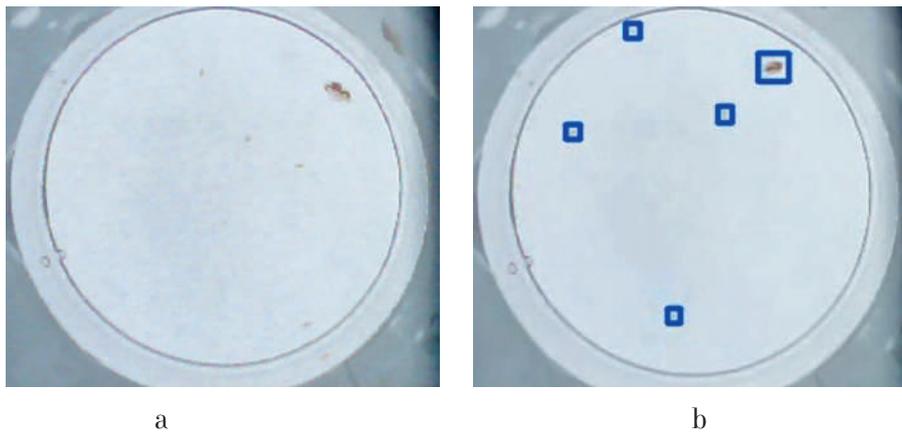


Рис. 4. Пример обнаружения дафний двух возрастов в ёмкостях малого объёма (100 мл):
а – исходное изображение, б – изображение с обнаруженными особями
Fig. 4. The detection of daphnia of two ages in small volume containers (100 mL):
a – original image, b – image with detected individuals

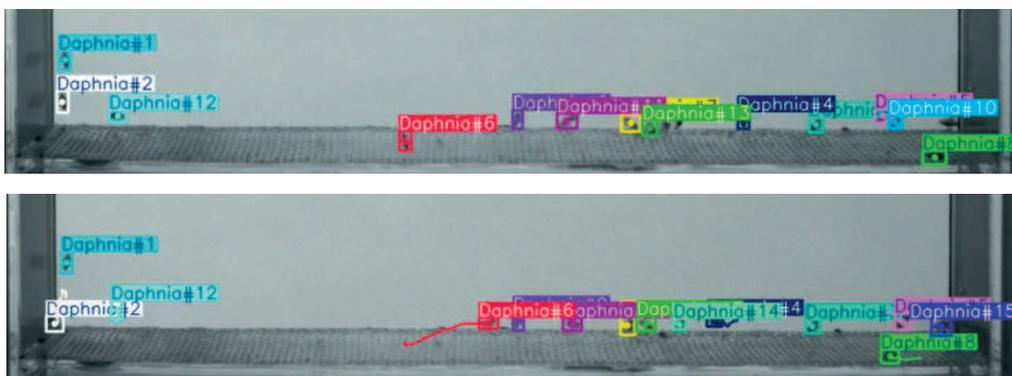


Рис. 5. Результат работы алгоритма обнаружения *D. magna* с функциями их отслеживания и подсчёта
Fig. 5. The result of the *D. magna* detection algorithm with tracking and counting functions

Заключение

Выполненная работа показала, что современные нейросети обнаруживают и подсчитывают одинаковые мезообъекты с высоким уровнем точности. В практическом плане решение подобной задачи необходимо при реализации методик биотестирования, когда операции производятся с монокультурой, не имеющей видового разнообразия. Приведённые в работе примеры показывают, что методы биоиндикации, где требуется обнаружение организмов разных видов, тоже в будущем могут быть дополнены возможностями нейросетей. В комплексе такие результаты являются значительным достижением в биодиагностике.

В представленной работе разработан и апробирован алгоритм обнаружения биообъектов *Daphnia magna* на основе СНС YOLOv8s, а с помощью встроенных функций «Object Tracking» и «Object Counting» реализованы процедуры подсчёта и отслеживания объектов. Алгоритм хорошо обнаруживает дафний при небольшой их концентрации в наблюдаемом объёме воды и хорошем разрешении изображения (до 100%). Метрики оценки качества работы алгоритма обнаружения достигают значений: mAP – 89,8%; точность – 88,4%; полнота – 87,4%.

Получение фотоизображений и их последующая обработка рекомендуются для фиксации множественных опытных данных, которые невозможно оценить одновременно одним исполнителем или даже несколькими. Для получения более детальных экспериментальных данных (скорости движения, прироста модельной популяции, гибели особей) можно использовать видеоданные, в том числе в режиме реального времени.

Алгоритм можно адаптировать для других однотипных мезообъектов. Подобное использование нейросетей позволит снизить временные затраты и трудоёмкость методов биотестирования, повысить достоверность результатов обработки данных.

Литература

1. Olkova A.S., Tovstik E.V. Computer vision – the frontier of modern environmental diagnostics: a review // *Pertanika J. Sci. Technol.* 2024. V. 32. No. 4. P. 1591–1607. doi: 10.47836/pjst.32.4.08
2. Николенко С.И., Кадурич А.С., Архангельская Е.В. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2018. 480 с.

3. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. М.: ДМК Пресс, 2018. 652 с.
4. Zhang J., Li C., Rahaman M.M., Yao Y., Ma P., Zhang J., Zhao X., Jiang T., Grzegorzec M. A comprehensive review of image analysis methods for microorganism counting: from classical image processing to deep learning approaches // *Artif. Intell. Rev.* 2022. V. 55. No. 4. P. 2875–2944. doi: 10.1007/s10462-021-10082-4
5. Boukouvalas D.T., Prates R.A., Leal C.R.L., de Araújo S.A. Automatic segmentation method for CFU counting in single plate-serial dilution // *Chemom. Intell. Lab. Syst.* 2019. V. 195. Article No. 103889. doi: 10.1016/j.chemolab.2019.103889
6. Rani P., Kotwal S., Manhas J. An intelligent species level deep learning-based framework in automatic classification of microscopic bacteria images // *Innovations in Computational Intelligence and Computer Vision. Advances in Intelligent Systems and Computing.* V. 1424. Singapore: Springer, 2022. P. 597–604. doi: 10.1007/978-981-19-0475-2_52
7. Zhang J., Li C., Kosov S., Grzegorzec M., Shirahama K., Jiang T., Sun C., Li Z., Li H. LCU-Net: A novel low-cost U-Net for environmental microorganism image segmentation // *Pattern Recogn.* 2021. V. 115. Article No. 107885. doi: 10.1016/j.patcog.2021.107885
8. Каплуненко Д.Д., Зотов С.С., Суботэ А.Е., Фищенко В.К. Применение нейронных сетей для классификации биологических объектов по подводным камерам МЭС острова Попова // *Подводные исследования и робототехника.* 2022. № 1 (39). С. 72–79. doi: 10.37102/1992-4429_2022_39_01_07
9. Багаев С.М., Медведева Е.В. Экспериментальная оценка точности мультиклассовой сегментации объектов на спутниковых снимках на основе модифицированной свёрточной нейронной сети U-net // *Современные проблемы дистанционного зондирования Земли из космоса.* 2021. T. 18. № 6. С. 35–45. doi: 10.21046/2070-7401-2021-18-6-35-45
10. Lv C., Cao S., Zhang Y., Xu G., Zhao B. Methods studies for attached marine organisms detecting based on convolutional neural network // *Energy Rep.* 2022. V. 8. Suppl. 13. P. 1192–1201. doi: 10.1016/j.egyrs.2022.08.131
11. Roboflow [Электронный ресурс] <https://universe.roboflow.com/chris-11tuh/daphnia-gvaud> (Дата обращения: 03.01.2025).
12. Kaggle [Электронный ресурс] <https://www.kaggle.com/datasets/davidumaa/daphniamagnaimage-dataset> (Дата обращения: 03.01.2025).
13. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single Shot MultiBox Detector // *Computer Vision – ECCV 2016: Lecture Notes in Computer Science.* V. 9905. Cham: Springer, 2016. P. 21–37. doi: 10.1007/978-3-319-46448-0_2
14. He D., Ren R., Li K., Zou Z., Ma R., Qin Y., Yang W. Urban rail transit obstacle detection based on Improved R-CNN // *Measurement.* 2022. V. 196. Article No. 111277. doi: 10.1016/j.measurement.2022.111277.

15. Ma Y., Xiao W., Wang J., Kuang X., Mo R., He Y., Feng J., Wei H., Zheng L., Li Y., Liu P., He H., He Y., Chen L., Lin Z., Fan X. Automated counting and classifying *Daphnia magna* using machine vision // *Aquat. Toxicol.* 2024. V. 276. Article No. 107126. doi: 10.1016/j.aquatox.2024.107126

16. Yu G., Cai R., Su J., Hou M., Deng R. U-YOLOv7: A network for underwater organism detection // *Ecol. Inform.* 2023. V. 75. Article No. 102108. doi: 10.1016/j.ecoinf.2023.102108

17. Jiang L., Wu L. Enhanced YOLOv8 network with Extended Kalman Filter for wildlife detection and tracking in complex environments // *Ecol. Inform.* 2024. V. 84. Article No. 102856. doi: 10.1016/j.ecoinf.2024.

18. Saputra F., Suryanto M.E., Audira G., Luong C.T., Hung C.H., Roldan M.J., Vasquez R.D., Hsiao C.D. Using DeepLabCut for markerless cardiac physiology and toxicity estimation in water fleas (*Daphnia magna*) // *Aquat. Toxicol.* 2023. V. 263. Article No. 106676. doi: 10.1016/j.aquatox.2023.106676

19. Кидов А.А., Иволга Р.А., Кондратова Т.Э., Грода О.С., Демянчик В.В., Ерашкин В.О., Кидова Е.А. Влияние плотности посадки на личиночное развитие камышовый жабы (*Epidalea calamita*) (по результатам лабораторных исследований) // *Теоретическая и прикладная экология.* 2024. № 3. С. 217–225. doi: 10.25750/1995-4301-2024-3-217-225

20. Цицашвили Г.Ш., Бочарников В.Н., Краснопе-ев С.М., Осипова М.А. Графовые алгоритмы для расчёта распределения следов амурского тигра на территории Приморского края // *Теоретическая и прикладная экология.* 2024. № 3. С. 20–28. doi: 10.25750/1995-4301-2024-3-020-028

References

1. Olkova A.S., Tovstik E.V. Computer vision – the frontier of modern environmental diagnostics: a review // *Pertanika J. Sci. Technol.* 2024. V. 32. No. 4. P. 1591–1607. doi: 10.47836/pjst.32.4.08

2. Nikolenko S.I., Kadurin A.S., Arkhangel'skaya E.V. Deep learning. Immersion in the world of neural networks. Sankt-Peterburg: Piter, 2018. 480 p. (in Russian).

3. Goodfellow I., Bengio Y., Courville A. Deep learning. Moskva: DMK Press, 2018. 652 p. (in Russian).

4. Zhang J., Li C., Rahaman M.M., Yao Y., Ma P., Zhang J., Zhao X., Jiang T., Grzegorzec M. A comprehensive review of image analysis methods for microorganism counting: from classical image processing to deep learning approaches // *Artif. Intell. Rev.* 2022. V. 55. No. 4. P. 2875–2944. doi: 10.1007/s10462-021-10082-4

5. Boukouvalas D.T., Prates R.A., Leal C.R.L., de Araújo S.A. Automatic segmentation method for CFU counting in single plate-serial dilution // *Chemom. Intell. Lab. Syst.* 2019. V. 195. Article No. 103889. doi: 10.1016/j.chemolab.2019.103889

6. Rani P., Kotwal S., Manhas J. An intelligent species level deep learning-based framework in automatic

classification of microscopic bacteria images // *Innovations in computational intelligence and computer vision. Advances in Intelligent Systems and Computing.* V. 1424. Singapore: Springer, 2022. P. 597–604. doi: 10.1007/978-981-19-0475-2_52

7. Zhang J., Li C., Kosov S., Grzegorzec M., Shirahama K., Jiang T., Sun C., Li Z., Li H. LCU-Net: A novel low-cost U-Net for environmental microorganism image segmentation // *Pattern Recogn.* 2021. V. 115. Article No. 107885. doi: 10.1016/j.patcog.2021.107885

8. Kaplunenko D.D., Zotov S.S., Subote A.E., Fischenko V.K. Neural-network-based classification of biological object images taken by underwater cameras // *Underwater Investigations and Robotics.* 2022. No. 1 (39). P. 72–79 (in Russian). doi: 10.37102/1992-4429_2022_39_01_07

9. Bagaev S.M., Medvedeva E.V., Experimental assessment of the accuracy of multiclass segmentation of objects in satellite images based on a modified convolutional neural network U-net // *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa.* 2021. V. 18. No. 6. P. 35–45 (in Russian). doi: 10.21046/2070-7401-2021-18-6-35-45

10. Lv C., Cao S., Zhang Y., Xu G., Zhao B. Methods studies for attached marine organisms detecting based on convolutional neural network // *Energy Rep.* 2022. V. 8. Suppl. 13. P. 1192–1201. doi: 10.1016/j.egyr.2022.08.131

11. Roboflow [Internet resource] <https://universe.roboflow.com/chris-11tuh/daphnia-gvaud> (Accessed: 03.01.2025).

12. Kaggle [Internet resource] <https://www.kaggle.com/datasets/davidumaa/daphniamagnaimagedataset> (Accessed: 03.01.2025).

13. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single Shot MultiBox Detector // *Computer Vision – ECCV 2016: Lecture Notes in Computer Science.* V. 9905. Cham: Springer, 2016. P. 21–37. doi: 10.1007/978-3-319-46448-0_2

14. He D., Ren R., Li K., Zou Z., Ma R., Qin Y., Yang W. Urban rail transit obstacle detection based on Improved R-CNN // *Measurement.* 2022. V. 196. Article No. 111277. doi: 10.1016/j.measurement.2022.111277

15. Ma Y., Xiao W., Wang J., Kuang X., Mo R., He Y., Feng J., Wei H., Zheng L., Li Y., Liu P., He H., He Y., Chen L., Lin Z., Fan X. Automated counting and classifying *Daphnia magna* using machine vision // *Aquat. Toxicol.* 2024. V. 276. Article No. 107126. doi: 10.1016/j.aquatox.2024.107126

16. Yu G., Cai R., Su J., Hou M., Deng R. U-YOLOv7: A network for underwater organism detection // *Ecol. Inform.* 2023. V. 75. Article No. 102108. doi: 10.1016/j.ecoinf.2023.102108

17. Jiang L., Wu L. Enhanced YOLOv8 network with Extended Kalman Filter for wildlife detection and tracking in complex environments // *Ecol. Inform.* 2024. V. 84. Article No. 102856. doi: 10.1016/j.ecoinf.2024.102856

18. Saputra F., Suryanto M.E., Audira G., Luong C.T., Hung C.H., Roldan M.J., Vasquez R.D., Hsiao C.D. Using DeepLabCut for markerless cardiac physiology and toxicity estimation in water fleas (*Daphnia magna*) // Aquat. Toxicol. 2023. V. 263. Article No. 106676. doi: 10.1016/j.aquatox.2023.106676

19. Kidov A.A., Ivolga R.A., Kondratova T.E., Groda O.S., Demyanchik V.V., Erashkin V.O., Kidova E.A. Effect of stocking density on larval development of the

Natterjack toad (*Epidalea calamita*), based on the laboratory results // Theoretical and Applied Ecology. 2024. No. 3. P. 217–225 (in Russian). doi: 10.25750/1995-4301-2024-3-217-225

20. Ciciashvili G.Sh., Bocharnikov V.N., Krasnopeev S.M., Osipova M.A. Graph algorithms for calculating the distribution of the Amur tiger tracks in Primorsky Krai // Theoretical and Applied Ecology. 2024. No. 3. P. 20–28 (in Russian). doi: 10.25750/1995-4301-2024-3-020-028