

The use of artificial intelligence technologies as an element of improving the methodology of environmental monitoring of the Black Sea

Original Article

LIMNOLOGY
FRESHWATER
BIOLOGYEgorkin A.A.^{1,2*}, Andreeva N.A.¹¹Institute of natural and technical systems, 14 Gogol str., Sevastopol, 299011, Russia²FGKVOU VPO «Black Sea Higher Naval Order of the Red Star School named after P.S. Nakhimov», Dybenko St. 1a, Sevastopol, 299028, Russia

ABSTRACT. This article is devoted to the results of an experimental study, the purpose of which was to evaluate the possibility of using artificial intelligence technologies to improve the methodology of environmental monitoring of the Black Sea using the computer vision model (YOLO). The basis of environmental monitoring of water bodies is the determination of pollution, the saprobic index was chosen as its quantitative characteristic in this study. Saprobity is characterized by the degree of contamination of the reservoir with organic substances and their decomposition products. It is determined by the species composition of organisms (saprobiotics) living in water and their number (frequency of occurrence). Microalgae of periphyton, which serve as indicators for the presence of organic substances, were selected as saprobiotics. The composition and quantity of microalgae involved in the microfouling process were determined using the “fouling glasses” method by installing glasses in the coastal water area under study. The identification and calculation of the frequency of occurrence of microalgae present at a certain point in time in the water area was carried out by microscopy of microfouling samples. A certain composition of microalgae made it possible to calculate the saprobic index of the studied water body and draw a conclusion about its contamination. This method requires the participation of highly qualified specialists and the time required to process the microscopy results. In this regard, artificial intelligence technologies were used to accelerate the process as an element of improving the methodology of environmental monitoring of the Black Sea area. The use of the computer vision (YOLO) model made it possible to reduce the study time and assess the quality of the water body, which confirmed the effectiveness of the proposed technology in order to improve environmental monitoring of water bodies.

Keywords: bioindication, saprobity, microalgae, environmental monitoring, neural networks, computer vision

For citation: Egorkin A.A., Andreeva N.A. The use of artificial intelligence technologies as an element of improving the methodology of environmental monitoring of the Black Sea // Limnology and Freshwater Biology. 2026. - № 4. - P. 258-282. DOI: 10.31951/2658-3518-2026-A-4-258

1. Introduction

Environmental monitoring of coastal waters is carried out in various ways, the choice of which is determined by the type of pollutants in the aquatic environment.

Pollution occurs when precipitation containing pollutants falls into a water body, effluents (discharges) of polluted waters from the territory of industrial facilities, and emergency situations when working with petroleum products.

One of the methods for determining water pollution is the bioindication method. The bioindication method as a monitoring improvement element involves

assessing the quality of the natural environment based on the state of living organisms living in a given water body. The method is based on observations of the composition and abundance of indicator species - organisms that are the most sensitive to environmental changes. The bioindication method was chosen as the most sensitive to changes in the aquatic environment as a result of anthropogenic impact.

Algae as bioindicators react quickly and predictably to a wide range of pollutants. They serve as early indicators of environmental degradation. To characterize the level of water contamination with organic substances, the concept of reservoir saprobity is used (Egorkin and Andreeva, 2026).

*Corresponding author. E-mail address: egorkin1974@yandex.ru (A.A. Egorkin)

Received: June 22, 2026;

Accepted after revised: July 26, 2026;

Available online: August 28, 2026

© Author(s) 2026. This work is distributed under the Creative Commons Attribution-NonCommercial 4.0 International License.



Saprobity is the quantification of biological species living in water, called saprobionts. Microalgae of periphyton were used as saprobionts. They have a set of physiological and biochemical features that determine their ability to live in water with a certain level of organic matter (degree of contamination). Oligosaprobic, mesosaprobic, and polysaprobic (the most polluted) reservoirs are distinguished. Each type of saprobiont has a saprobic index.

The morphology of peripheral microalgae varies depending on the type of substrate and environmental conditions; they can form filamentous, mucous or film-like structures, as well as have a wide variety of forms, from unicellular to colonial and, depending on the species, have a different configuration, size and color. In general, periphyton is a community of microscopic organisms that colonize underwater surfaces in the aquatic environment. Microalgae of the periphyton take part in the processes of biological self-purification and formation of water quality. This is especially true in the coastal zone of the sea (Kovtun and Snigireva, 2012).

One of the methods currently used to determine the composition and quantity of microalgae is the “fouling glasses” method (Egorkin and Andreeva, 2026). The method is carried out by immersing specially selected glasses in the aquatic environment of the coastal zone of the Black Sea.

The identification and calculation of the frequency of occurrence of microalgae present at a certain point in time in the water area was carried out by microscopy of microfouling samples. This method requires highly qualified specialists and time to process the microscopy results. In this regard, to accelerate the process, artificial intelligence technologies were supposed to be used as an element of improving the methodology of environmental monitoring of the Black Sea area (Egorkin and Andreeva, 2026). The approbation of the proposed improvement method is presented in this article.

The purpose of the experimental study is to evaluate the possibility of using artificial intelligence technologies to improve the methodology of environmental monitoring of the water area using the computer vision model (YOLO).

Research objectives:

1. Analysis of the results of the application of the bioindication method and determination of saprobity.
2. Development of an algorithm for the use of artificial intelligence technologies - computer vision to determine the reliability.

2. Materials and methods

Bioindication and determination of saprobity were carried out using the method of “fouling glasses” installed in the coastal water area under study.

The following actions were performed:

- three glasses (size 25 x 75 mm) were fixed in a rubber tube with slots at a distance of 50 mm from each other;
- the first glass was immersed to a depth of 100 mm;

- the glasses were immersed and removed from the water on a monthly basis;
- periphyton organisms were examined in a suspension of scrapings;
- to study the morphology of cyanobacteria and microalgae of the periphyton in lifetime preparations, a Levenhuk 740T light microscope was used at magnification x 400;
- the cultures were photographed using a digital nozzle using the appropriate Levenhuk ToupView computer program and further image processing in Adobe Photoshop CS3 Extended;
- the taxonomic affiliation of microalgae was established using determinants (Guslyakov et al., 1992; Komárek and Anagnostidis, 1998; 2005).

After determining the species composition of microalgae, the saprobic index (S) was calculated, which was calculated using the formula:

$$S = \frac{\sum_{i=1}^N (s_i - h_i)}{\sum_{i=1}^N h_i}, \quad (1)$$

where:

N is the number of selected indicator types.;

h_i is the relative abundance of the i -th species (Table 1);

s_i is the individual saprobic index of the first type.

The saprobic index is the average value of the saprobity of all found species, taking into account their abundance.

The calculation of the number of specimens of an individual representative of the periphyton community of microalgae in a certain period (month), out of the total number, was carried out according to the formula:

$$B = \frac{N}{A} 100, \quad (2)$$

where

B – percentage of occurrence, %;

N – the number of representatives of this taxon in all the studied visual fields;

A – the number of examined visual fields.

The saprobic index was specified with an accuracy of 0.01. The degree of contamination of the reservoir was determined by the value of the saprobic index: 0.5 – 1.5 – o – oligosaprobe zone (clean water), 1.51 – 2.5 – β – mesosaprobe zone (moderately polluted water), 2.51 – 3.5 – α – mesosaprobe zone (dirty water), 3.51 – 4.50 – p – polysaprobe zone (heavily polluted water) (Stupina, 1977).

Table 1. The ratio of relative abundance and frequency of organisms.

Occurrence	The number of copies of one type, % of the total number	h_i , scores
Very rarely	< 1	1
Rarely	2–3	2
Rather common	4–10	3
Often	10–20	5
Very often	20–40	7
En masse	40–100	9

The considered methodology for the saprobity determining and, accordingly, the assessment of the water body quality was carried out as a result of a long time period. To speed up the process in order to improve the methodology of environmental monitoring based on data from the application of the “fouling glasses” method, further experimental research using artificial intelligence technologies was conducted.

Modern artificial intelligence methods make it possible to automate image analysis, which is especially important when working with large amounts of microscopic data. In microscopic studies, this makes it possible to significantly speed up information processing and reduce the influence of the subjective factor characteristic of traditional visual analysis (Pawłowski et al., 2022).

There are three main directions in computer vision tasks: classification, detection and segmentation of images. Segmentation is a more detailed approach and includes highlighting the exact boundaries of an object, which makes it possible to more fully describe the shape of microalgae and their morphological features.

The YOLOv11 family model, which is widely used for image processing, was used as a tool (Spahn et al., 2022; Vasil'ev et al., 2025). Modern versions, such as YOLOv11-seg, have implemented the ability to solve detection and segmentation problems within a single architecture. The model provides information about the object's class, the probability of recognition, and its position in the image. During segmentation, it additionally generates an object mask.

The algorithm for improving the methodology included the following steps:

1. Compilation of a database and photo gallery of microalgae taxa.
2. Determination of the occurrence of various microalgae taxa based on the microbiology expert's work results.
3. Selection of microalgae taxa for the study.
4. Creation of training, test and validation samples for modeling.
5. Training, validation and testing of a neural network model based on the YOLO architecture.
6. Approbation of a model for assessing the ecological condition of the studied water body.

3. Results

3.1. Compilation of a database and photo gallery of microalgae taxa

The study of periphyton communities on «fouling glasses» in the coastal waters of Sevastopol was carried out for eight years. In the study of coastal waters with anthropogenic pollution, from 29 to 37 systematic units of microalgae were identified (Andreeva, 2015).

The main representatives of the periphyton in different years were diatoms of the genera *Navicula* Bory, *Nitzschia* Hassall, *Pinnularia* Ehrenberg,

Cylindrotheca Gottlob Ludwig Rabenhorst, and *Amphora* Ehrenberg ex Kützinger. In some periods, *Achnanthes* de Saint-Vincent, *Bacillaria* J.F. Gmelin, *Licmophora* Carl Adolph Agardh, *Striatella* C. Agardh, *Thalassionema* A. Grunow ex C. Mereschowsky, and some others actively developed, as well as representatives of oscillatory cyanobacteria, including those belonging to the genus *Spirulina* (*Arthrospira* Sitenberger ex Gomont). Green (Chlorophyta) and Dinophyta algae were somewhat less common.

Figure 1 shows some representatives of the periphyton communities of the coastal water area of Sevastopol.

3.2. Determination of the occurrence of various microalgae taxa based on the microbiology expert's work results

The average data on the occurrence of different representatives of the periphyton for 2018 are shown in (Fig. 2). The data for 2018 was selected for analysis due to the fact that a complete set of data is available for this period without missing months.

3.3. Selection of microalgae taxa for the study

In order to determine the saprobic index and assess the quality of the studied reservoir based on the analysis of literary sources, individual saprobic indexes were determined for the microalgae presented in (Figs. 1 and 2) (Table 2) (Barinova, 1996; Stupina, 1977).

3.4. Creation of training, test and validation samples for modeling

Micrographs of selected microalgae taxa were specially prepared for use in modeling based on artificial intelligence (computer vision) technology.

The first step was to assign unique names to the images corresponding to the name of the taxon in order to eliminate possible errors during further processing. The “Taxon name” format was used as the naming template. *_1.jpeg*“, where the part before the underscore character corresponds to the name of the microalgae genus, and the numeric index after it corresponds to the ordinal number of the image.

Next, the image array was divided into subsamples, which were used in the process of training the model. In accordance with the requirements of the YOLO family model, the data was divided into three parts: the training sample (train) – 70% of the images, the validation sample (validation) – 15% and the test sample (test) – 15%.

The separation was carried out separately for each type of microalgae, observing the specified ratio, which made it possible to maintain the balance of classes at all stages of training and ensure a correct assessment of the quality of the model. As a result, 3907 images were included in the training sample, 841 in the validation sample, and 860 in the test sample.




Fig.1. Representatives of the periphyton communities of the coastal water area of Sevastopol.
1, 2, 3 – Oscillatoriales Schaffner; 4 – *Navicula*; 5,6 – *Pinnularia*; 7 – *Cymbella* C.Agardh; 8 – *Amphora*; 9 – *Cocconeis* Ehrenberg; 10 – *Entomoneis* Ehrenberg; 11 – *Cylandrotheca*; 12 – *Pleurosigma* W. Smith; 13 – *Nitzschia*; 14, 15 – *Bacillaria*; 16 – *Thalassionema*; 17 – *Coscinodiscus* Ehrenberg; 18 – *Skeletonema* R. K. Greville; 19 – *Melosira* C.A. Agardh; 20 – *Achnanthes*; 21 – *Licmophora*; 22 – *Rhizosolenia* Brightwell; 23, 24 – Dinoflagellata; 25 – ribbon-shaped organisms.




Fig.2. Occurrence of the main ten types of microalgae in periphyton samples during monthly sampling and manual counting in 2018.

Table 2. Taxa with their saprobity zones and saprobic indexes.

№ п/п	Taxon	The zone of saprobity	Index (s)	Minimum (s)	Max. (s)
1	<i>Achnanthes</i>	o – α	1.50	0.10	2.70
2	<i>Amphipleura</i> Kützing	o – β	1.10	0.50	1.80
3	<i>Amphora</i>	o – β	0.80	0.10	1.65
4	<i>Bacillaria</i>	β	2.80	2.80	2.80
5	<i>Cocconeis</i>	o – β	0.90	0.50	1.75
6	<i>Coscinodiscus</i>	β	2.15	1.80	2.50
7	<i>Oscillatoriales</i>	α	3.00	2.50	3.50
8	<i>Cylindrotheca</i>	β	2.15	1.80	2.50
9	<i>Cymbella</i>	β	1.71	1.71	1.71
10	<i>Desmogonium</i> C. G. Ehrenberg	o – β	1.15	0.50	1.80
11	<i>Dinophyta</i>	β	2.05	1.80	2.30
12	<i>Diploneis</i>	β	2.15	1.80	2.50
13	<i>Entomoneis</i>	β – α	2.50	2.00	3.00
14	<i>Licmophora</i>	β	2.05	1.80	2.30
15	<i>Melosira</i>	o	1.00	0.50	1.50
16	<i>Navicula</i>	β – α	2.45	2.00	2.90
17	<i>Nitzschia</i>	β – α	2.85	2.70	3.00
18	<i>Pinnularia</i>	o – β	1.40	0.20	2.20
19	<i>Pleurosigma</i>	β	2.20	1.80	2.50
20	<i>Rhizosolenia</i>	o	1.20	1.20	1.20
21	<i>Skeletonema</i>	β	2.25	1.80	2.50
22	<i>Spirulina</i>	o – β	1.50	1.00	2.00
23	<i>Striatella</i>	β	2.15	1.80	2.50
24	<i>Tabellaria</i> Ehrenberg ex F.T.Kützing	o – β	0.75	0.10	1.40
25	<i>Talassionema</i>	β	2.15	1.80	2.50

At the next stage, the image markup was performed using the CVAT (Computer Vision Annotation Tool) program (Holicheva et al., 2025). A project was created in the program in which classes (labels) corresponding to 25 taxa of microalgae were defined. A task was created inside the project, corresponding to the subsamples into which the previously prepared images were uploaded (Fig. 1).

Next, the images were marked up to implement the segmentation task. The marking was performed using the polygonal tool of the CVAT program. (Fig. 3).

After the markup was completed, the data was exported from CVAT. Each task was saved as a separate archive. To train YOLO models, a format was used that includes images and their corresponding markup text files.

Each image corresponds to a.txt file containing information about the classes of objects and the coordinates of their location relative to the size of the image. In this case, the name of the text file must completely match the name of the corresponding image, which is a prerequisite for correct training of the model.

As a result of data preparation, a directory structure was formed, including the folders “images” and “labels”, each of which contains the subfolders “train”, “validation” and “test”. The “images” folder contains the source images, and the “labels” folder contains the markup files. The distribution of the number of all objects in folders according to taxon classes is shown in (Fig. 4).

This structure is used as input data for training the selected YOLO11x-seg model. The model used belongs to the more complex and accurate versions of the YOLO family and is characterized by an increased number of parameters, which should ensure a higher quality of object recognition.

3.5. Training, validation and testing of a neural network model based on the YOLO architecture

The process of learning, validation and testing in computer vision is a strictly regulated sequence of actions. At the first stage, the model sees only the training sample, and its task is to minimize the loss function by adjusting the weights of the convolutional layers using the error backpropagation algorithm. The model sequentially processes small portions of images, calculates gradients, and updates parameters. Training is an iterative process of comparing data and metrics on a specific sample, which reflects the ability of the model to remember these relationships present in the training dataset. After each epoch or after a certain number of iterations, the currently trained model is run through a validation dataset that was not involved in updating the weights. At this stage, the same metrics are calculated, but their dynamics serve as an indicator of the generalizing ability of the model.



Fig.3. An example of marking microalgae in the CVAT program.

After the training is completed (that is, the validation metrics have reached an acceptable level), the testing stage begins. Up to this point, the test sample is kept in isolation. It is not used either for hyperparameter selection or for early stopping of model training. When all the settings are completed, the model is run through the test dataset once, and the resulting metrics are calculated. These values are considered an objective assessment of the quality of the model in conditions close to real operation.

As part of the study, a microalgae segmentation model was trained to identify objects at the pixel level. The training was performed using the YOLO11x-seg architecture in segmentation mode with the following parameters: the input image size is 640×640 pixels, the number of epochs is 140, with standard data optimization and augmentation settings.

In the learning process, two types of metrics are formed: 1) by Box (detection) and 2) by masks (segmentation). The division into (Box) and (Mask) allows you to determine exactly where the failure occurs - the model does not find objects well or poorly defines the contours of segmented elements.

During the training process, graphs of the loss function on the training and validation set of images are analyzed: Box Loss is an error in the coordinates of the box, Seg Loss is an error in the pixels of the mask, Cls Loss is an error in determining the class, DFL Loss is an error in the regression of boundaries (corners, edges) (Figs. 5 and 6). Loss functions are mathematical expressions that quantify how much a model's predictions deviate from the actual values.

The error estimation on the training and validation set of images serves as an indicator by which the learning state of the model is determined.

One of the important metrics used to evaluate the learning outcomes of the "computer vision" model is the Mean Average Precision (mAP), which reflects the effectiveness of object detection as a number from 0 to 1. It is calculated twice: 1) separately for bounding boxes (Box mAP) and 2) for pixel masks (Mask mAP) (Fig. 7). This allows you to understand where the model is stronger in detecting objects or in accurately highlighting their contours. Both metrics are based on curves (accuracy and completeness) Precision-Recall for each class (Fig. 8).




Fig.4. Distribution of the number of objects according to taxon classes.




Fig.5. Graph of changes in loss functions on the training set of images.




Fig.6. Graph of changes in loss functions on the validation set of images.




Fig.7. Graph of changes in the average (respectively, 25 classes of taxa) mAP values depending on the epoch of learning.




Fig.8. Graph of curves (accuracy and completeness) Precision-Recall averages (corresponding to 25 classes of taxa), depending on the age of study.

Two main variants were used in the results of the YOLO model:

- mAP@0.5 (a more “soft” standard). A hit is counted if the prediction intersects with the truth (IoU is a metric in computer vision that measures the degree of overlap between the predicted area (for example, the bounding box or segmentation mask) and the true area (ground truth—) more than 50%. It shows well whether the model is able to find objects at all.;
- mAP@0.5:0.95 (a stricter “gold standard”). The mAP averages over 10 IoU thresholds from 0.5 to 0.95. It requires a perfect contour match from the model and is considered the main indicator for comparing models.

Figure 9 shows images of the F1 metric (or F1-measure, F1-score), which is the average parameter between Precision and Recall. This is a balanced indicator that shows how well the model works overall, taking into account both types of errors (false positives and missing objects).

Since the validation sample is not involved in training, but it is involved in setting up hyperparameters (according to its metrics, it was decided to stop training (early stop) at epoch 143, it was decided to choose the model size and apply augmentation) It was concluded that the model, although indirectly, “saw” the validation sample. Based on this, a test sample is always used that the model has not “seen”. The results of the final assessment on the test set (860 images, 1072 objects) are presented in Table 3.

3.6. Approbation of the model for assessment of the ecological state of the investigated water body

After testing the model, an array of microscopic images was processed to assess the quality of the water body. The initial data used were images obtained during observations of the water area for the period from 2017 to 2026, however, data for 2018 were selected for fur-

ther analysis, since, as noted earlier, there was a complete set of data for it without missing months. The set also featured photographs with multicomponent and structurally complex microalgae. The choice is also justified by the need to test the model’s operability using such complex examples.

In order to automate the process of practical application of the trained segmentation model, a Python web application was developed. The application provides loading of the trained YOLO model, performing segmentation, processing results and calculating statistical indicators.

The application automatically calculates the number of processed images, the number of images with and without detected objects, the total number of objects found, the average number of objects in all images, the distribution by gender, the index of reliability and processing time. To automate calculations, Table 2 was pre-integrated into the application. During image processing, the segmentation model determined whether objects belonged to the corresponding taxa and counted the number of representatives of each genus.

To assess the correctness of the model, images with selected objects and their masks were obtained (Fig. 10).

To assess the quality of the proposed methodology for improving environmental monitoring using artificial intelligence (computer vision) technologies, a comparative analysis of the results of automatic recognition of microalgae with data obtained by an expert during manual processing of the same images was performed. The results of the calculation and determination of the generic composition performed by a specialist during microscopy were used as reference data.

The comparison was based on the total number of objects discovered for each genus in 2018. The results of the expert calculation of the main taxa are shown in (Fig. 2), and the data of the automated analysis in (Fig. 11).

For clarity, a comparative graph of the distribution of the number of microalgae by genus was constructed (Fig. 12), which shows two dependencies (the




Fig.9. The F1 value averaged over all classes: 1 – for Box (reaches 0.70 with a confidence threshold of 0.342); 2 – for Mask (reaches 0.68 with a confidence threshold of 0.337).




Fig.10. Examples of visual application results.




Fig.11. Occurrence of the main ten types of microalgae in periphyton samples during monthly sampling with automatic counting in 2018.




Fig.12. Comparison of the average annual proportions of all taxa depending on the image processing method.

Table 3. General metrics for all classes based on the assessment results in the test sample.

Type of bounding box	Precision	Recall	mAP@0.5	mAP@0.5:0.95
Box (detection)	0.742	0.793	0.8125	0.6617
Mask (segmentation)	0.739	0.773	0.7909	0.5336

results of expert manual assessment and automated counting), and the contribution of each taxon to the overall saprobic index was studied depending on the image processing method (Fig. 13).

The article also analyzed the dynamics of changes in the saprobic index depending on the season of the year and assessed the contribution of the influence of the taxa with the largest increase in number in the determination using automatic counting (Fig. 14).

4. Discussion


During the automated analysis and subsequent comparison with the expert assessment, discrepancies were identified due to a number of factors related to both the characteristics of the training sample and the specifics of the research objects themselves.

One of the key reasons for errors is the data markup technique used. The markup was performed according to the standards used for typical computer vision objects, which turned out to be insufficient for multicomponent and structurally complex microalgae. As a result, three main types of errors related to this factor were identified.

First, there is a morphological similarity of individual genera of microalgae, which affects their correct recognition by the model and leads to classification errors. Examples are the genera *Amphipleura* and *Navicula*, *Amphora* and *Diploneis*, *Bacillaria* and *Talassionema*, *Cylindrotheca* and *Rhizosolenia*, *Melosira* and *Skeletonema*, *Striatella* and *Tabellaria* (Fig. 15). The model confuses these genera with each other.

Second, segmentation errors are recorded, which manifest themselves in combining closely spaced objects into one mask or in the excessive division of one object into several. This error occurred due to the incomplete and consistent markup of the data, which leads to incorrect definition of the boundaries of objects.

Third, the limitations of the model in recognizing complex shapes characteristic of a number of taxa are revealed. Despite the fact that the data markup was performed correctly for typical objects, it was found that in order to improve recognition accuracy, it is necessary to take into account individual structural elements (for example, covers, heterocysts, akinets, damaged cells), as well as use specialized marking approaches focused on the features of microscopic objects. In the future, the marking technique will be revised, taking into account

**Fig.13.** The contribution of each taxon to the overall saprobic index, depending on the image processing method.




Fig.14. Dynamics of changes in the saprobic index depending on the image processing method and calculated with adjustments minus abnormally high values of individual taxa.

the allocation of additional morphological classes and a more detailed description of the structure of objects.

Fourth, the distribution of data is an important factor. Due to the lack of the necessary high-quality images for marking up the dataset, the sample turned out to be uneven (Fig. 4 – 4 genera contain more than 400, 4 more genera ~ 300 and at the same time 9 genera ~ 100 photos). As a result, the model demonstrates higher accuracy for common genera and less stable results for rare taxa. This led to a shift in the final estimates and affected the correctness of the analysis of the saprobic index and, accordingly, the assessment of the ecological state of the water body (Fig. 14). However, by adjusting the calculation of the saprobic index by subtracting the taxa that showed abnormal growth due to the imbalance of the training sample, the water body can be classified as conditionally clean during the year.

Fifth, a group of factors is related to the characteristics of the original images. First of all, it is the presence of background elements (bubbles, inorganic inclusions), which can be perceived by the model as parts of recognition objects (Fig. 16). This indicates the need for more thorough data filtering and, if necessary, the introduction of a separate “background” class when training the model. The crowding of objects, the quality and clarity of their boundaries, the noise level and the contrast of images have an additional impact on object recognition (Fig. 16). It should be noted that the quality of the source photos is generally acceptable for training, but the specifics of microscopic objects require stricter requirements for the visual character-

istics of the data.

An important role is also played by the extension of the boundaries of the taxon beyond the boundaries of the photograph and the overlap of objects in the images, which leads to ignoring incomplete objects in the definition, since the model was trained on whole photographs of microalgae with a continuous closed boundary (Fig. 16).

The results obtained show that the use of standard methods without adaptation to the subject area inevitably leads to distortions, but at the same time confirm the fundamental applicability of the chosen approach. This allows us to consider the identified limitations not as disadvantages of the model, but as guidelines for its further development, aimed at moving from formal recognition to a more meaningful analysis of the structure and condition of microalgae.

5. Conclusions

A technique for automated recognition of microalgae for assessing the state of the aquatic environment has been developed and tested.

Using computer vision techniques, a segmentation model was trained to isolate and classify objects in microscopic images.

A web application has been created that provides a full cycle of microscopic image processing.

The proposed technique uses automatic object counting, which improves the objectivity and reproducibility of the results.



Fig.15. Examples of genera that are similar in appearance.




Fig.16. Features of the initial data: а – organic matter; б – clarity and noise level; B – overlap and exit of the boundaries of the taxon beyond the boundaries of photography.

A comparison of the results of the model with the expert assessment showed a satisfactory agreement in determining the structure of microalgae communities, despite the presence of some quantitative discrepancies.

The analysis made it possible to identify the main limitations of the developed model related to the specifics of microscopic objects, markup features and the structure of the training sample, while it was found that these limitations are manageable.

Acknowledgements

The research was carried out within the framework of the state assignment of the Institute of Natural and Technical Systems on the topic (state registration no. 124013000609-2) “Fundamental and applied research of patterns and mechanisms of formation of regional environmental and climate changes under the influence of global processes in the ocean-atmosphere system” (FFMM-2024-0017)” and the cooperation agreement with the Black Sea State Educational Institution of Higher Professional Education Higher Naval Order of the Red Star School named after P.S. Nakhimov”.

Conflict of interest

The authors declare that there is no conflict of interest.

References

- Andreeva N.A. 2015. Mikrotsenozy v morskoy akvatorii s povyshennoy stepen'yu evτροφikatsii [Microcenoses in a marine area with increased eutrophication]. *Sistemy kontrolya okruzhayushchey sredy* [Environmental Control Systems] 2(22): 111–122. (in Russian)
- Barinova S.S. 1996. Atlas of algae – indicators of saprobity (Russian Far East). Vladivostok: Dal'nauka. (in Russian)
- Egorkin A.A., Andreeva N.A. 2026. Improvement of environmental monitoring methods for water bodies using artificial intelligence technologies. In: *Modern methods of assessment and rational use of aquatic biological resources: Proceedings of the III International Scientific and Practical Conference*, Moscow, November 17–21, 2025. Moscow: VNIRO. EDN GDDHZZ, pp. 50–53. (in Russian)
- Guslyakov N.E., Zakordonets O.A., Gerasimiyuk V.P. 1992. Atlas of benthic diatom algae of the northwestern Black Sea and adjacent water bodies. Kiev: Naukova dumka. (in Russian)
- Holicheva A.A., Kozlov K.S., Boiko D.A. et al. 2025. Deep generative modeling of annotated bacterial biofilm images. *npj Biofilms and Microbiomes* 11: 16. DOI: [10.1038/s41522-025-00647-4](https://doi.org/10.1038/s41522-025-00647-4)
- Komárek J., Anagnostidis K. 1998. Cyanoprokaryota 1. Chroococcales. In: Ettl H., Gärtner G., Heynig H., Mollenhauer D. (eds.). *Süßwasserflora von Mitteleuropa* 19/1. Jena: Gustav Fischer.
- Komárek J., Anagnostidis K. 2005. Cyanoprokaryota 2. Oscillatoriales. In: Büdel B., Krienitz L., Gärtner G., Schagerl M. (eds.) *Süßwasserflora von Mitteleuropa* 19/2. Heidelberg: Elsevier/Spektrum.
- Kovtun O.A., Snigireva A.A. 2012. Guidelines for the study of phytomicrobenthos and phytoperiphyton. Odessa: Odessa National University named after I.I. Mechnikov. (in Russian)
- Pawłowski J., Majchrowska S., Golan T. 2022. Generation of microbial colonies dataset with deep learning style transfer. *Scientific Reports* 12: 5212. DOI: [10.1038/s41598-022-09264-z](https://doi.org/10.1038/s41598-022-09264-z)
- Spahn C., Gómez-de-Mariscal E., Laine R.F. et al. 2022. DeepBacs for multi-task bacterial image analysis using open-source deep learning approaches. *Communications Biology* 5: 688. DOI: [10.1038/s42003-022-03634-z](https://doi.org/10.1038/s42003-022-03634-z)
- Stupina V.V. 1977. Unifitsirovannyye metody issledovaniya kachestva vod. Ch. 3. Unified methods for water quality research. Part 3. Methods of biological analysis of water. Appendix 1. Indicators of saprobity. Moscow: Nauka. (in Russian)
- Vasil'ev M.E., Shalimov A.S., Savina O.A. 2025. Review of YOLO versions: single-stage convolutional neural network model. *Universum: Technical Sciences* 6(135). (in Russian)

Применение технологий искусственного интеллекта как элемента совершенствования методики экологического мониторинга акватории Черного моря

Оригинальная статья

LIMNOLOGY
FRESHWATER
BIOLOGYЕгоркин А.А.^{1,2*}, Андреева Н.А.¹¹ ФГБНУ Институт природно-технических систем, ул. Гоголя д. 14, г. Севастополь, 299011, Россия² ФГКВОУ ВПО «Черноморское высшее военно-морское орденов Нахимова и Красной Звезды училище имени П.С.Нахимова», ул. Дыбенко, д. 1а, г. Севастополь, 299028, Россия

АННОТАЦИЯ. Данная статья посвящена результатам экспериментального исследования, целью которого было оценить возможность применения технологий искусственного интеллекта для совершенствования методики экологического мониторинга акватории Черного моря, осуществляемого использованием модели компьютерного зрения (YOLO). Основой экологического мониторинга водных объектов является определение загрязненности, количественной характеристикой которой в данном исследовании был выбран индекс сапробности. Сапробность характеризуется степенью загрязнённости водоёма органическими веществами и продуктами их распада. Она определяется по видовому составу организмов (сапробионтов), обитающих в воде и их количеству (частоты встречаемости). В качестве сапробионтов были выбраны микроводоросли перифитона, служащие индикаторами на присутствие органических веществ. Состав и количество микроводорослей, участвующих в процессе микрообрастания, определялись применением метода «стеклообрастания» путем установления стекол в исследуемой прибрежной акватории. Идентификация и подсчет частоты встречаемости микроводорослей, присутствующих в определенный момент времени в акватории, осуществлялся при микроскопировании образцов микрообрастаний. Определенный состав микроводорослей позволил вычислить индекс сапробности исследуемого водного объекта и сделать вывод о его загрязненности. Данный способ требует участия высококвалифицированных специалистов и затраты времени для обработки результатов микроскопирования. В связи с этим, для ускорения процесса в качестве элемента совершенствования методики экологического мониторинга акватории Черного моря, были использованы технологии искусственного интеллекта. Применение модели компьютерного зрения (YOLO) позволило сократить время исследования, оценить качество водного объекта, что подтвердило эффективность применения предлагаемой технологии с целью совершенствования экологического мониторинга водных объектов.

Ключевые слова: биоиндикация, сапробность, микроводоросли, экологический мониторинг, нейронные сети, компьютерное зрение

Для цитирования: Егоркин А.А., Андреева Н.А. Применение технологий искусственного интеллекта как элемента совершенствования методики экологического мониторинга акватории Черного моря // Limnology and Freshwater Biology. 2026. - № 4. - С. 258-282. DOI: [10.31951/2658-3518-2026-A-4-258](https://doi.org/10.31951/2658-3518-2026-A-4-258)

1. Введение

Экологический мониторинг водных объектов приморской территории производится различными способами, выбор которых определяется видом загрязняющих веществ водной среды.

Загрязнение водного объекта происходит при выпадении осадков, содержащих загрязняющие вещества, стоков (сбросов) загрязненных вод с территории промышленных объектов и при аварийных ситуациях при работе с нефтепродуктами.

*Автор для переписки. Адрес e-mail: egorkin1974@yandex.ru (А.А. Егоркин)

Поступила: 22 июня 2026;

Принята после доработки: 26 июля 2026;

Опубликована online: 28 августа 2026

© Автор(ы) 2026. Эта работа распространяется под международной лицензией Creative Commons Attribution-NonCommercial 4.0.



Одним из методов определения загрязнения водной среды является метод биоиндикации. Метод биоиндикации как элемент совершенствования мониторинга предполагает оценку качества природной среды по состоянию обитающих в данном водном объекте живых организмов. В основе метода лежат наблюдения за составом и численностью видов индикаторов - организмов, которые наиболее чувствительны к изменениям среды. Метод биоиндикации был выбран как наиболее чувствительный к изменениям водной среды в результате антропогенного воздействия.

Водоросли как биоиндикаторы быстро и предсказуемо реагируют на широкий спектр загрязняющих веществ. Они служат ранними индикаторами ухудшения состояния окружающей среды. Для характеристики уровня загрязненности воды органическими веществами используют понятие сапробности водоема (Егоркин и Андреева, 2026).

Сапробность – количественное определение биологических видов, обитающих в воде, называемыми сапробионтами. В качестве сапробионтов использовались микроводоросли перифитона. Они обладают комплексом физиолого-биохимических особенностей, обуславливающих их способность обитать в воде с тем или иным уровнем содержания органических веществ (степенью загрязнения). Выделяют олигосапробные, мезосапробные и полисапробные (наиболее загрязненные) водоемы. Каждому виду сапробионта соответствует индекс сапробности.

Морфология перифитонных микроводорослей варьирует в зависимости от типа субстрата и условий среды; они могут образовывать нитевидные, слизистые или пленкообразные структуры, а также иметь широкое разнообразие форм, от одноклеточных до колониальных и, в зависимости от вида, иметь различную конфигурацию, размер и цвет. В целом, перифитон представляет собой сообщество микроскопических организмов, колонизирующих подводные поверхности в водной среде. Микроводоросли перифитона принимают участия в процессах биологического самоочищения и формирования качества вод. Особенно актуально это в прибрежной зоне моря (Ковтун и Снигирева, 2012).

Одним из методов, используемых в настоящее время для определения состава и количества микроводорослей, является метод «стекло обростания» (Егоркин и Андреева, 2026). Метод осуществляется путем погружения специально подобранных стекол в водную среду прибрежной зоны Черного моря.

Идентификация и подсчет частоты встречаемости микроводорослей, присутствующих в определенный момент времени в акватории, осуществлялся при микроскопировании образцов микрообрастаний. Данный метод требует наличие высококвалифицированных специалистов и затраты времени для обработки результатов микроскопирования. В связи с этим для ускорения процесса, в качестве элемента совершенствования методики экологического мониторинга акватории Черного моря, предполагалось использовать технологии

искусственного интеллекта (Егоркин и Андреева, 2026). Апробация предлагаемого метода усовершенствования представлена в данной работе.

Цель экспериментального исследования - оценить возможность применения технологий искусственного интеллекта для совершенствования методики экологического мониторинга акватории, осуществляемого использованием модели компьютерного зрения (YOLO).

Задачи исследования:

1. Анализ результатов применения метода биоиндикации и определение сапробности.
2. Разработка алгоритма применения технологий искусственного интеллекта - компьютерного зрения для определения сапробности.

2. Материалы и методы

Биоиндикация и определение сапробности проводились с применением метода «стекло обростания», установленных в исследуемой прибрежной акватории.

Были проведены следующие действия:

- три стекла (размер 25 x 75 мм) закрепляли в резиновой трубке с прорезями на расстоянии 50 мм друг от друга;
- первое стекло погружали на глубину 100 мм;
- погружение и выемку стекол из воды проводили ежемесячно;
- организмы перифитона исследовали в суспензии соскобов;
- для изучения морфологии цианобактерий и микроводорослей перифитона в прижизненных препаратах использовали световой микроскоп Levenhuk 740T при увеличении x 400;
- фотографирование культур проводилось при помощи цифровой насадки с использованием соответствующей компьютерной программы Levenhuk ToupView и дальнейшей обработкой изображений в программе Adobe Photoshop CS3 Extended;
- таксономическую принадлежность микроводорослей устанавливали при помощи определителей (Гусляков и др., 1992; Komárek and Anagnostidis, 1998; 2005).

После определения видового состава микроводорослей был рассчитан индекс сапробности (S), который вычислялся по формуле:

$$S = \frac{\sum_{i=1}^N (s_i - h_i)}{\sum_{i=1}^N h_i}, \quad (1)$$

где:

N – число выбранных видов-индикаторов;

h_i – относительная численность i-го вида (Таблица 1);

s_i – индивидуальный индекс сапробности i-го вида.

Индекс сапробности – это среднее значение

Таблица 1. Соотношение значений относительного обилия и частот встречаемости организмов.

Встречаемость	Количество экземпляров одного вида, % от общего количества	h_p , баллы
Очень редко	< 1	1
Редко	2–3	2
Нередко	4–10	3
Часто	10–20	5
Очень часто	20–40	7
Массово	40–100	9

сапробности всех найденных видов, с учетом их обилия.

Расчёт количества экземпляров отдельного представителя перифитонного сообщества микроводорослей в определённый период (месяц) от общего количества производился по формуле:

$$B = \frac{N}{A} 100, \tag{2}$$

где:

- B – процент встречаемости, %;
- N – количество представителей данного таксона во всех исследованных полях зрения;
- A – число исследованных полей зрения.

Индекс сапробности указывался с точностью до 0,01. По значению индекса сапробности определялась степень загрязнения водоема: 0,5 – 1,5 – α – олигосапробная зона (чистая вода), 1,51 – 2,5 – β – мезосапробная зона (умеренно загрязненная вода), 2,51 – 3,5 – α – мезосапробная зона (грязная вода), 3,51 – 4,50 – ρ – полисапробная зона (сильно загрязненная вода) (Ступина, 1977).

Рассмотренная методика определения сапробности и соответственно оценка качества водного объекта осуществлялась в результате длительного временного периода. Для ускорения процесса с целью совершенствования методики проведения экологического мониторинга на основе данных применения метода «стекло обрастания» было проведено дальнейшее экспериментальное исследование с применением технологий искусственного интеллекта.

Современные методы искусственного интеллекта позволяют автоматизировать анализ изображений, что особенно актуально при работе с большим объёмом микроскопических данных. В микроскопических исследованиях это даёт возможность значительно ускорить обработку информации и снизить влияние субъективного фактора, характерного для традиционного визуального анализа (Pawłowski et al., 2022).

В задачах компьютерного зрения выделяют три основных направления: классификацию, детекцию и сегментацию изображений. Сегментация является более детализированным подходом и включает выделение точных границ объекта, что дает возможность более полно описать форму микроводорослей и их морфологические признаки.

В работе в качестве инструмента использовалась модель семейства YOLOv11, которая широко применяется для обработки изображений (Spahn et al., 2022; Васильев и др., 2025). В современных

версиях, таких как YOLOv11-seg, реализована возможность решения задач детекции и сегментации в рамках единой архитектуры. Модель предоставляет информацию о классе объекта, вероятности распознавания и его положении на изображении, а при сегментации дополнительно формирует маску объекта.

Алгоритм совершенствования методики включал следующие этапы:

1. Составление базы данных и фотогалереи таксонов микроводорослей.
2. Определение встречаемости различных таксонов микроводорослей по результатам работы эксперта - микробиолога.
3. Выбор таксонов микроводорослей для проведения исследования.
4. Создание обучающей, валидационной и тестовой выборки для моделирования.
5. Обучение, валидация и тестирование модели нейронной сети на основе архитектуры YOLO.
6. Апробация модели для оценки экологического состояния исследуемого водного объекта.

3. Результаты

3.1. Составление базы данных и фотогалереи таксонов микроводорослей

Изучение перифитонных сообществ на «стёклах обрастания» в прибрежных акваториях Севастополя проводилось в течение восьми лет. При исследовании прибрежной акватории с антропогенным загрязнением было выявлено от 29 до 37 систематических единиц микроводорослей (Андреева, 2015).

Основными представителями перифитона в разные годы являлись диатомовые водоросли родов *Navicula* Bory, *Nitzschia* Hassall, *Pinnularia* Ehrenberg, *Cylindrotheca* Gottlob Ludwig Rabenhorst, *Amphora* Ehrenberg ex Kützinger. В отдельные периоды активно развивались *Achnanthes* de Saint-Vincent, *Bacillaria* J.F. Gmelin, *Licmophora* Carl Adolph Agardh, *Striatella* C. Agardh, *Thalassionema* A. Grunow ex C. Mereschkowsky и некоторые другие, а также представители осцилляториевых цианобактерий, в том числе, принадлежащих к роду *Spirulina* (*Arthrospira* Sitzenberger ex Gomont). Несколько реже встречались зелёные (*Chlorophyta*) и динофитовые (*Dinophyta*) водоросли.

На (Рис. 1) показаны некоторые представители перифитонных сообществ прибрежной акватории Севастополя.

3.2. Определение встречаемости различных таксонов микроводорослей по результатам работы эксперта - микробиолога

Средние данные по встречаемости разных представителей перифитона за 2018 г. представлены на (Рис. 2). Данные за 2018 год для анализа были выбраны в связи с тем, что для данного периода имеется полный набор данных без пропусков по месяцам.

3.3. Выбор таксонов микроводорослей для проведения исследования

С целью определения индекса сапробности и оценки качества исследуемого водоема на основе анализа литературных источников были определены для представленных на (Рис. 1 и 2) микроводорослей индивидуальные индексы сапробности (Таблица 2) (Барина, 1996; Ступина, 1977).

3.4. Создание обучающей, валидационной и тестовой выборки для моделирования

Микрофотографии выбранных таксонов микроводорослей подвергались специальной подготовке для использования в моделировании на основе технологии искусственного интеллекта (компьютерного зрения).

Первым этапом было присвоение изображениям уникальных имен, соответствующих названию таксона, для исключения возможных ошибок при дальнейшей обработке. В качестве шаблона наименования использовался формат «Название таксона_1.jpeg», где часть до символа подчёркивания соответствует названию рода микроводорослей, а числовой индекс после него порядковому номеру изображения.

Далее выполнено разделение массива изображений на подвыборки, которые были использованы в процессе обучения модели. В соответствии с требованиями модели семейства YOLO данные были распределены на три части: обучающая выборка (train) – 70% изображений, валидационная выборка (validation) – 15% и тестовая выборка (test) – 15%.



Рис.1. Представители перифитонных сообществ прибрежной акватории Севастополя.

1, 2, 3 – *Oscillatoriales* Schaffner; 4 – *Navicula*; 5, 6 – *Pinnularia*; 7 – *Cymbella* C. Agardh; 8 – *Amphora*; 9 – *Cocconeis* Ehrenberg; 10 – *Entomoneis* Ehrenberg; 11 – *Cylindrotheca*; 12 – *Pleurosigma* W. Smith; 13 – *Nitzschia*; 14, 15 – *Bacillaria*; 16 – *Thalassionema*; 17 – *Coscinodiscus* Ehrenberg; 18 – *Skeletonema* R. K. Greville; 19 – *Melosira* C.A. Agardh; 20 – *Achnanthes*; 21 – *Licmophora*; 22 – *Rhizosolenia* Brightwell; 23, 24 – *Dinoflagellata* Bütschli; 25 – Лентообразные.




Рис.2. Встречаемость основных десяти типов микроводорослей в образцах перифитона при ежемесячном отборе проб и ручном подсчете в 2018 году.

Таблица 2. Таксоны с их зонами сапробности и сапробными индексами.

№ п/п	Таксон	Зона сапробности	Индекс (s)	Мин. (s)	Макс. (s)
1	<i>Achnanthes</i>	о – α	1,50	0,10	2,70
2	<i>Amphipleura</i> Kützing	о – β	1,10	0,50	1,80
3	<i>Amphora</i>	о – β	0,80	0,10	1,65
4	<i>Bacillaria</i>	β	2,80	2,80	2,80
5	<i>Cocconeis</i>	о – β	0,90	0,50	1,75
6	<i>Coscinodiscus</i>	β	2,15	1,80	2,50
7	<i>Oscillatoriales</i>	α	3,00	2,50	3,50
8	<i>Cylindrotheca</i>	β	2,15	1,80	2,50
9	<i>Cymbella</i>	β	1,71	1,71	1,71
10	<i>Desmogonium</i> C. G. Ehrenberg	о – β	1,15	0,50	1,80
11	<i>Dinophyta</i>	β	2,05	1,80	2,30
12	<i>Diploneis</i>	β	2,15	1,80	2,50
13	<i>Entomoneis</i>	β – α	2,50	2,00	3,00
14	<i>Licmophora</i>	β	2,05	1,80	2,30
15	<i>Melosira</i>	о	1,00	0,50	1,50
16	<i>Navicula</i>	β – α	2,45	2,00	2,90
17	<i>Nitzschia</i>	β – α	2,85	2,70	3,00
18	<i>Pinnularia</i>	о – β	1,40	0,20	2,20
19	<i>Pleurosigma</i>	β	2,20	1,80	2,50
20	<i>Rhizosolenia</i>	о	1,20	1,20	1,20
21	<i>Skeletonema</i>	β	2,25	1,80	2,50
22	<i>Spirulina</i>	о – β	1,50	1,00	2,00
23	<i>Striatella</i>	β	2,15	1,80	2,50
24	<i>Tabellaria</i> Ehrenberg ex F.T.Kützing	о – β	0,75	0,10	1,40
25	<i>Talassionema</i>	β	2,15	1,80	2,50

Разделение осуществлялось отдельно для каждого рода микроводорослей с соблюдением указанного соотношения, что позволило сохранить баланс классов на всех этапах обучения и обеспечить корректную оценку качества модели. В результате в обучающую выборку было включено 3907 изображений, в валидационную – 841, в тестовую – 860.

На следующем этапе разметка изображений выполнялась с использованием программы CVAT (Computer Vision Annotation Tool) (Holicheva et al., 2025). В программе был создан проект, в котором были заданы классы (labels), соответствующие 25 таксонам микроводорослей. Внутри проекта было сформировано задание, соответствующее подборкам, в которые были загружены ранее подготовленные изображения (Рис. 1).

Далее была проведена разметка изображений для реализации задачи сегментации. Разметка выполнялась с использованием полигонального инструмента программы CVAT. (Рис. 3).

После завершения разметки данные экспортировались из CVAT. Каждое задание сохранялось в виде отдельного архива. Для обучения моделей YOLO использовался формат, включающий изображения и соответствующие им текстовые файлы разметки.

Каждому изображению соответствует файл формата.txt, содержащий информацию о классах объектов и координатах их расположения относительно размеров изображения. При этом наименование текстового файла должно полностью совпадать с именем соответствующего изображения, что является необходимым условием корректного обучения модели.

В результате подготовки данных была сформирована структура каталогов, включающая папки «images» и «labels», каждая из которых содержит подпапки «train», «validation» и «test». Папка «images» содержит исходные изображения, а папка «labels» – файлы разметки. Распределение количества всех объектов в папках согласно классам таксонов представлено на (Рис. 4).

Данная структура используется в качестве входных данных для обучения выбранной модели YOLO11x-seg. Используемая модель относится к более сложным и точным версиям семейства YOLO и характеризуется увеличенным числом параметров, что должно обеспечивать более высокое качество распознавания объектов.

3.5. Обучение, валидация и тестирование модели нейронной сети на основе архитектуры YOLO

Процесс обучения, валидации и тестирования в «компьютерном зрении», представляет собой строго регламентированную последовательность действий. На первом этапе модель видит только обучающую выборку, и её задача – минимизировать функцию потерь, корректируя веса свёрточных слоёв с помощью алгоритма обратного распространения ошибки. Модель последовательно обрабатывает небольшие порции изображений, вычисляет градиенты и обновляет параметры. Обучение – это итеративный процесс сопоставления данных и метрик на определенной выборке, который отражает способность модели запоминать эти соотношения, присутствующие в тренировочном наборе данных. После каждой эпохи или через определённое количество итераций обученная на данный момент модель прогоняется через валидационный набор данных, который не участвовал в обновлении весов. На этом этапе вычисляются те же метрики, но их динамика служит индикатором обобщающей способности модели.

После того как обучение завершено (то есть валидационные метрики достигли приемлемого уровня) наступает этап тестирования. Тестовая выборка до этого момента хранится в изоляции. Она не используется ни для подбора гиперпараметров, ни для ранней остановки обучения модели. Когда все настройки закончены, модель прогоняется через тестовый набор данных один раз, при этом вычисляются итоговые метрики. Эти значения считаются объективной оценкой качества модели в условиях, приближенных к реальной эксплуатации.



Рис.3. Пример разметки микроводорослей в программе CVAT.




Рис.4. Распределение количества объектов согласно классам таксонов.

В рамках исследования было проведено обучение модели сегментации микроводорослей, позволяющей выделять объекты на уровне пикселей. Обучение выполнялось с использованием архитектуры YOLO11x-seg в режиме сегментации с параметрами: размер входного изображения 640×640 пикселей, количество эпох - 140, при стандартных настройках оптимизации и аугментации данных.

В процессе обучения формируются метрики двух типов: 1) по ограничивающим рамкам (Box) (детекция) и 2) по маскам (Mask) (сегментация). Разделение на (Box) и (Mask) позволяет определить, где именно происходит сбой - модель плохо находит объекты или плохо определяет контуры сегментированных элементов.

В процессе обучения анализируются графики функции потерь на тренировочном и валидационном наборе изображений: Box Loss – ошибка в координатах бокса, Seg Loss – ошибка в пикселях маски, Cls Loss – ошибка в определении класса, DFL Loss – ошибка в регрессии границ (углы, края) (Рис. 5 и 6). Функции потерь (loss functions) – математические выражения, количественно оценивающие, насколько предсказания модели отклоняются от фактических значений.

Оценка ошибок на тренировочном и валидационном наборе изображений служит показателем, по которому определяется состояние обучения модели.

Одной из важных метрик, применяемых для оценки результатов обучения модели «компьютерного зрения» является средняя точность (Mean Average Precision, mAP), которая отражает эффективность обнаружения объектов в виде числа от 0 до 1. Она рассчитывается дважды: 1) отдельно для ограничивающих рамок (Box mAP) и 2) для пиксельных масок (Mask mAP) (Рис. 7). Это позволяет понять, где модель сильнее в обнаружении объектов или в точности выделения их контуров. Обе

метрики строятся на основе кривых (точности и полноты) Precision-Recall для каждого класса (Рис. 8).

В результатах модели YOLO использовались два основных варианта:

- mAP@0.5 (более «мягкий» стандарт). Попадание засчитывается, если пересечение предсказания с истиной (IoU – метрика в компьютерном зрении, которая измеряет степень перекрытия между предсказанной областью (например, ограничивающей рамкой (bounding box) или маской сегментации) и истинной областью (ground truth – эталонной разметкой)) больше 50%. Хорошо показывает, умеет ли модель вообще находить объекты;
- mAP@0.5:0.95 (более строгий «золотой стандарт»). Усредняет mAP по 10 порогам IoU от 0.5 до 0.95. Требуем от модели идеального совпадения контуров и считается основным показателем для сравнения моделей.

На Рисунке 9 представлены изображения метрики F1 (или F1-мера, F1-score) являющейся средним параметром между точностью (Precision) и полнотой (Recall). Это сбалансированный показатель, который показывает, насколько хорошо модель работает в целом, учитывая оба типа ошибок (ложные срабатывания и пропущенные объекты).

Так как валидационная выборка не участвует в обучении, но она участвует в настройке гиперпараметров (по её метрикам было принято решение остановить обучение (ранняя остановка) на 143 эпохе, было принято решение о выборе размера модели и о применении аугментации) был сделан вывод, что модель хоть и косвенно, но «видела» валидационную выборку. Исходя из этого, всегда используется тестовая выборка, которую модель не «видела». Результаты итоговой оценки на тестовом наборе (860 изображений, 1072 объекта) представлены в Таблице 3.




Рис.5. График изменения функций потерь на тренировочном наборе изображений.




Рис.6. График изменения функций потерь на валидационном наборе изображений.




Рис.7. График изменения средних (соответственно 25 классам таксонов) значений mAP в зависимости от эпохи обучения.




Рис.8. График кривых (точности и полноты) Precision-Recall средних (соответственно 25 классам таксонов) в зависимости от эпохи обучения.




Рис.9. Значение F1, усредненное по всем классам: 1 – для Box (достигает 0.70 при пороге уверенности (confidence) равном 0.342); 2 – для Mask (достигает 0.68 при пороге уверенности (confidence) равном 0.337).

3.6. Апробация модели для оценки экологического состояния исследованного водного объекта

После тестирования модели была выполнена обработка массива микроскопических изображений для оценки качества водного объекта. В качестве исходных данных использовались снимки, полученные в ходе наблюдений за период с 2017 по 2026 гг., однако для дальнейшего анализа были выбраны данные за 2018 год, поскольку, как отмечалось ранее, именно для него имелся полный набор данных без пропусков по месяцам. Также набор отличался фотографиями с наличием многокомпонентных и структурно сложных микроводорослей. Выбор также обоснован необходимостью проверки работоспособности модели на таких сложных примерах.

С целью автоматизации процесса практического применения обученной модели сегментации было разработано веб-приложение на языке Python. Приложение обеспечивает загрузку обученной модели YOLO, выполнение сегментации, обработку результатов и расчёт статистических показателей.

Приложение автоматически рассчитывает количество обработанных изображений, число снимков с обнаруженными объектами и без них, общее количество найденных объектов, среднее число объектов на всех изображениях, распределение по родам, индекс сапробности и время обработки. Для автоматизации расчётов в приложение была предварительно интегрирована Таблица 2. В процессе обработки изображений модель сегментации определяла принадлежность объектов к соответствующим таксонам и подсчитывала количество представителей каждого рода.

Для оценки корректности работы модели были получены изображения с выделенными объектами и их масками (Рис. 10).

Для оценки качества предлагаемой методики совершенствования экологического мониторинга с использованием технологий искусственного интеллекта (компьютерного зрения) был выполнен сравнительный анализ результатов автоматического распознавания микроводорослей с данными, полученными экспертом при ручной обработке тех же изображений. В качестве эталонных данных использовались результаты подсчёта и определения родового состава, выполненные специалистом в процессе микроскопирования.

Сравнение проводилось на основе общего количества обнаруженных объектов по каждому роду за 2018 год. Результаты экспертного подсчёта основных таксонов представлены на (Рис. 2), а данные автоматизированного анализа на (Рис. 11).

Для наглядности был построен сравнительный график распределения количества микроводорослей по родам (Рис. 12), на котором представлены две зависимости (результаты экспертной ручной оценки и автоматизированного подсчёта), а также изучен вклад каждого таксона в общий сапробный индекс в зависимости от способа обработки изображений (Рис. 13).

В работе также была проанализирована динамика изменения сапробного индекса в зависимости от сезона года и оценен вклад влияния таксонов с наибольшим ростом количества в определении с применением автоматического подсчёта (Рис. 14).

4. Обсуждение

В ходе проведения автоматизированного анализа и последующего сравнения с экспертной оценкой были выявлены расхождения, обусловленные рядом факторов, связанных как с особенностями обучающей выборки, так и со спецификой самих объектов исследования.

Таблица 3. Общие метрики по всем классам по результатам оценки на тестовой выборке.

Тип ограничивающей рамки	Precision	Recall	mAP@0.5	mAP@0.5:0.95
Box (детекция)	0,742	0,793	0,8125	0,6617
Mask (сегментация)	0,739	0,773	0,7909	0,5336




Рис.10. Примеры визуальных результатов работы приложения.




Рис.11. Встречаемость основных десяти типов микроводорослей в образцах перифитона при ежемесячном отборе проб при автоматическом подсчете в 2018 году.




Рис.12. Сравнение среднегодовых долей всех таксонов в зависимости от способа обработки изображений.




Рис.13. Вклад каждого таксона в общий сапробный индекс в зависимости от способа обработки изображений.

Одной из ключевых причин возникновения ошибок является используемая методика разметки данных. Разметка была выполнена по стандартам, применяемым для типовых объектов компьютерного зрения, что оказалось недостаточным для многокомпонентных и структурно сложных микроводорослей. В результате были выявлены три основных типа ошибок, связанных с данным фактором.

Во-первых, наблюдается морфологическое сходство отдельных родов микроводорослей, что затрудняет их корректное распознавание моделью и приводит к ошибкам классификации. Примерами могут служить рода *Amphipleura* и *Navicula*, *Amphora* и *Diploneis*, *Bacillaria* и *Talassionema*, *Cylindrotheca* и *Rhizosolenia*, *Melosira* и *Skeletonema*, *Striatella* и *Tabellaria* (Рис. 15).

Модель путает эти рода между собой.

Во-вторых, фиксируются ошибки сегментации, проявляющиеся в объединении близко расположенных объектов в одну маску или в избыточном разделении одного объекта на несколько. Данная ошибка возникла из-за не вполне точной и согласованной разметке данных, что влечёт некорректное определение границ объектов.

В-третьих, выявлены ограничения модели при распознавании сложных форм, характерных для ряда таксонов. Несмотря на то, что разметка данных выполнена корректно для типовых объектов, было установлено, что для повышения точности распознавания необходимо учитывать отдельные структурные элементы (например, чехлы, гетероцисты, акинеты, повреждённые клетки), а также использовать специализированные подходы к разметке, ориентированные на особенности микроскопических




Рис.14. Динамика изменения сапробного индекса в зависимости от способа обработки изображений и рассчитанные с корректировкой за вычетом anomalно высоких значений отдельных таксонов.



Рис.15. Примеры родов, сходных по внешним параметрам.

объектов. В дальнейшем, методика разметки будет пересмотрена с учётом выделения дополнительных морфологических классов и более детализированного описания структуры объектов.

В-четвёртых, важным фактором является распределение данных. В силу отсутствия необходимых качественных снимков для разметки датасета выборка получилась неравномерной (Рис. 4 – 4 рода содержат более 400, ещё 4 рода ~300 и в то же время 9 родов ~100 фотографий). Вследствие этого модель демонстрирует более высокую точность для часто встречающихся родов и менее устойчивые результаты для редких таксонов. Это привело к смещению итоговых оценок и повлияло на корректность анализа сапробного индекса и соответственно оценки экологического состояния водного объекта (Рис. 14). Однако, скорректировав расчет значения сапробного индекса за счет вычитания таксонов, показавших аномальный рост в виду несбалансированности обучающей выборки, водный объект можно отнести к условно чистому в течение года.

В-пятых, группа факторов связана с особенностями исходных изображений. В первую очередь – это наличие фоновых элементов (пузырьки, неорганические включения), которые могут восприниматься моделью как части объектов распознавания (Рис. 16). Это указывает на необходимость более тщательной фильтрации данных и, при необходимости, введения отдельного класса «фон» при обучении модели. Дополнительное влияние на распознавание объектов оказывают скученность объектов, качество и чёткость их границ, уровень шумов и контрастность изображений (Рис. 16). При этом следует отметить, что качество исходных фотогра-

фий, в целом, является приемлемым для обучения, однако специфика микроскопических объектов требует более строгих требований к визуальным характеристикам данных.

Также существенную роль играет выход границ таксона за пределы фотографии и перекрытие объектов на изображениях, что приводит к игнорированию неполных объектов при определении, так как модель обучалась на цельных фотографиях микроводорослей со сплошной замкнутой границей (Рис. 16).

Полученные результаты показывают, что применение стандартных методов без адаптации к предметной области неизбежно приводит к искажениям, однако одновременно подтверждают принципиальную применимость выбранного подхода. Это позволяет рассматривать выявленные ограничения не как недостатки модели, а как ориентиры для её дальнейшего развития, направленного на переход от формального распознавания к более содержательному анализу структуры и состояния микроводорослей.

5. Выводы

Разработана и апробирована методика автоматизированного распознавания микроводорослей для оценки состояния водной среды.

Используя методы компьютерного зрения была обучена модель сегментации для выделения и классификации объектов на микроскопических изображениях.

Создано веб-приложение, обеспечивающее полный цикл обработки микроскопических изображений.




Рис.16. Особенности исходных данных: а – органика; б – четкость и уровень шума; в – перекрытие и выход границ таксона за пределы фотографии.

Предлагаемая методика использует автоматический подсчёт объектов, что позволяет повысить объективность и воспроизводимость результатов.

Сравнение результатов модели с экспертной оценкой показало удовлетворительное совпадение в определении структуры сообществ микроводорослей, несмотря на наличие отдельных количественных расхождений.

Проведённый анализ позволил выявить основные ограничения разработанной модели, связанные со спецификой микроскопических объектов, особенностями разметки и структурой обучающей выборки, при этом установлено, что данные ограничения носят устранимый характер.

Благодарности

Исследование выполнено в рамках государственного задания Института природно-технических систем по теме (№ госрегистрации 124013000609-2) «Фундаментальные и прикладные исследования закономерностей и механизмов формирования региональных изменений природной среды и климата под влиянием глобальных процессов в системе океан-атмосфера» (FFMM-2024-0017) и договора о сотрудничестве с ФГКВОУ ВПО «Черноморское высшее военно-морское ордена Красной Звезды училище имени П.С. Нахимова».

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Список литературы

Андреева Н.А. 2015. Микроценозы в морской акватории с повышенной степенью эвтрофикации. Системы контроля окружающей среды 2(22): 111–122.

Баринова С.С. 1996. Атлас водорослей – индикаторов сапробности. Владивосток: Дальнаука.

Васильев М.Е., Шалимов А.С., Савина О.А. 2025. Обзор версий YOLO: одноэтапная модель сверточной нейронной сети. *Universum: технические науки* 6(135).

Гусляков Н.Е., Загордонец О.А., Герасимюк В.П. 1992. Атлас диатомовых водорослей бентоса северо-западной части Черного моря и прилегающих водоемов. Киев: Наукова думка.

Егоркин А.А., Андреева Н.А. 2026. Совершенствование методики экологического мониторинга водных объектов с применением технологий искусственного интеллекта. В: Современные методы оценки и рационального использования водных биологических ресурсов: Материалы III международной научно-практической конференции (Москва, 17–21 ноября 2025 года, С. 50–53.

Ковтун О.А., Снигирева А.А. 2012. Методические указания по изучению фитомикробентоса и фитоперифитона. Одесса: Одесский национальный университет имени И.И. Мечникова.

Ступина В.В. 1977. Унифицированные методы исследования качества вод. Ч. 3. Методы биологического анализа вод. Приложение 1. Индикаторы сапробности. М.: Наука.

Holiceva A.A., Kozlov K.S., Boiko D.A. et al. 2025. Deep generative modeling of annotated bacterial biofilm images. *npj Biofilms and Microbiomes* 11: 16. DOI: [10.1038/s41522-025-00647-4](https://doi.org/10.1038/s41522-025-00647-4)

Komárek J., Anagnostidis K. 1998. Cyanoprokaryota 1. Chroococcales. In: Ettl H., Gärtner G., Heynig H., Mollenhauer D. (eds.). *Süßwasserflora von Mitteleuropa* 19/1. Jena: Gustav Fischer.

Komárek J., Anagnostidis K. 2005. Cyanoprokaryota 2. Oscillatoriales. In: Büdel B., Krienitz L., Gärtner G., Schagerl M. (eds.) *Süßwasserflora von Mitteleuropa* 19/2. Heidelberg: Elsevier/Spektrum.

Pawłowski J., Majchrowska S., Golan T. 2022. Generation of microbial colonies dataset with deep learning style transfer. *Scientific Reports* 12: 5212. DOI: [10.1038/s41598-022-09264-z](https://doi.org/10.1038/s41598-022-09264-z)

Spahn C., Gómez-de-Mariscal E., Laine R.F. et al. 2022. DeepBacs for multi-task bacterial image analysis using open-source deep learning approaches. *Communications Biology* 5: 688. DOI: [10.1038/s42003-022-03634-z](https://doi.org/10.1038/s42003-022-03634-z)