Информация об авторах

Кошелева Ольга Юрьевна, старший научный сотрудник лаборатории геоинформационного моделирования и картографирования агролесоландшафтов ФНЦ агроэкологии РАН (РФ, 400062, г. Волгоград, пр-т Университетский, 97), кандидат сельскохозяйственных наук, тел. 8 (917)640-50-31, e-mail: olya_ber@mail.ru. ORCID: 0000-0002-9616-2383

Шинкаренко Станислав Сергеевич, научный сотрудник лаборатории геоинформационного моделирования и картографирования агролесоландшафтов ФНЦ агроэкологии РАН (РФ, 400062, г. Волгоград, пр-т Университетский, 97), научный сотрудник отдела технологий спутникового мониторинга Института космических исследований РАН (РФ, 117997, г. Москва, ул. Профсоюзная, 84/32), кандидат сельскохозяйственных наук, 46-25-68, e-mail: shinkarenkos@vfanc.ru. ORCID: 0000-0002-9269-4489

Гордиенко Олег Андреевич, младший научный сотрудник лаборатории защиты почв от эрозии ФНЦ агроэкологии РАН (РФ, 400062, г. Волгоград, пр-т Университетский, 97); тел. 8 (8442) 46-25-67, e-mail: gordienko-o@vfanc.ru. ORCID: 0000-0001-5381-9114.

Омаров Роман Сергеевич, аспирант Санкт-Петербургского государственного университета (РФ, 199034, г. Санкт-Петербург, Университетская наб., 7/9), тел. 8 (917) 845-72-00, e-mail: st098989@student.spbu.ru. ORCID: 0000-0003-2762-3673.

Дубачева Анастасия Алексеевна, ведущий инженер отдела обеспечения ведения государственного водного реестра (ГВР) и АИС ГВР ФГБУ «Российский информационно-аналитический и научно-исследовательский водохозяйственный центр» (РФ, 400001, г. Волгоград, ул. Канунникова, 6/1); магистрант кафедры «География и картография» Волгоградского государственного университета (РФ, 400062, г. Волгоград, пр-т Университетский, 100), e-mail: dubatcheva.a@gmail.com ORCID: 0000-0003-3279-1460.

DOI: 10.32786/2071-9485-2021-03-45

CREATING A NEURAL NETWORK SERVICE FOR IDENTIFYING PROBLEM AREAS OF AGRICULTURAL FIELDS

I. S. Belousov, A. F Rogachev

Volgograd State Agrarian University, Volgograd

Received 25.06.2021

Submitted 27.08.2021

The publication has been prepared with the financial support of the RFBR under project No. 20-37-90142.

Summary

The creation of a neural network service for identifying problem areas of reclaimed agricultural fields is considered. The architectures of modern artificial neural networks are analyzed and the construction of a neural network for the subject area under study is justified. Recommendations on the construction of the client and server parts of the developed service are given.

Abstract

Introduction. Agricultural production requires the processing of significant amounts of information to solve various management problems. The development of neural network and cloud technologies makes it possible to process information in the cloud with the provision of access to computing power by the user. **Materials and methods.** The article describes the construction of artificial neural networks of various architectures - the ResNext, AlexNet, R-CNN models and their combinations, as well as modifications of the YOLO algorithms. As well as tools for creating a cloud computing runtime. **Results and conclusion.** The choice of service parameters for recognizing problem areas of reclaimed agricultural fields has been substantiated. Recommendations are given for performing preprocessing of the initial graphic data, methods of training the constructed ANNs. Recommendations are given for the development of the client and server parts of the system using the technologies and tools of CNN, PyTorch, CUDA. The strengths and weaknesses of their use for solving the problem of image recognition are identified using the example of problem areas of agricultural fields. The service can be used as an independent solution, as well as part of other systems. The studies carried out made it possible to formulate the following conclusions. The use of the developed classification ANN has shown that neu-

ral networks are able to successfully solve problems of recognizing the state of agricultural fields with the identification of defective areas of various nature. Modern infocommunication technologies make it possible to implement neural network computing in the cloud with the provision of convenient scaling of computing power. Cloud service can be implemented and monetized like SaaS.

Key words: *crop yield, yield forecasting, neural network recognition, cloud service, SaaS.*

Citation: Belousov I.S., Rogachev A. F. Creating a neural network service for identifying problem areas of agricultural fields. *Proc. of the Lower Volga Agro-University Comp.* 2021. 3(63). 439-448 (in Russian). DOI: 10.32786/2071-9485-2021-03-45.

Author's contribution. All authors of this research paper have directly participated in the planning, execution, or analysis of this study. All authors of this paper have read and approved the final version submitted.

Conflict of interest. The authors declare no conflict of interest.

УДК 631.3:635

СОЗДАНИЕ НЕЙРОСЕТЕВОГО СЕРВИСА ДЛЯ ВЫЯВЛЕНИЯ ПРОБЛЕМНЫХ УЧАСТКОВ СЕЛЬСКОХОЗЯЙСТВЕННЫХ ПОЛЕЙ

И. С. Белоусов, аспирант

А. Ф. Рогачев, доктор технических наук, профессор

Волгоградский государственный аграрный университет, г. Волгоград

Дата поступления в редакцию 25.06.2021

Дата принятия к печати 27.08.2021

Статья подготовлена при финансовой поддержке РФФИ по проекту No. 20-37-90142.

Актуальность. Сельскохозяйственное производство требует обработки значительных объемов информации для решения различных задач управления. Развитие нейросетевых и облачных технологий позволяет проводить обработку информации в облаке с предоставлением доступа к вычислительным мощностям пользователем. **Методы.** В статье описывается построение искусственных нейронных сетей различных архитектур-моделей ResNext, AlexNet, R-CNN и их комбинаций, а также модификаций алгоритмов YOLO, а также инструментов для создания среды выполнения вычислений в облаке. **Результаты.** Обоснован выбор параметров сервиса для распознавания проблемных участков мелиорируемых сельскохозяйственных полей. Приведены рекомендации по выполнению предобработки исходных графических данных, методам обучения построенных ИНС. Даны рекомендации по разработке клиентской и серверной частей системы с использованием технологий и инструментария CNN, PyTorch, CUDA. Выявлены сильные и слабые стороны их использования для решения задачи по распознаванию изображений на примере проблемных участков сельскохозяйственных полей. Сервис может быть использован как самостоятельное решение, так и как часть других систем. **Выводы.** Проведенные исследования позволили сформулировать следующие выводы. Использование разработанной классификационной ИНС показало, что нейросети способны успешно решать задачи по распознаванию состоянию сельскохозяйственных полей с выявлением дефектных участков различной природы. Современные инфокоммуникационные технологии позволяют реализовать нейросетевые вычисления в облаке с обеспечением удобного масштабирования вычислительных мощностей. Облачный сервис можно реализовать и монетизировать, как SaaS.

Ключевые слова: *урожайность сельскохозяйственных культур, прогнозирование урожайности, нейросетевое распознавание, облачные сервисы, SaaS.*

Цитирование: Белоусов И. С., Рогачев А. Ф. Создание нейросетевого сервиса для выявления проблемных участков сельскохозяйственных полей. *Известия НВ АУК.* 2021. 3(63). 439-448. DOI: 10.32786/2071-9485-2021-03-45.

Авторский вклад. Авторы исследования принимали непосредственное участие в планировании, выполнении и анализе результатов данного исследования. Авторы статьи ознакомились и одобрили представленный окончательный вариант.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Введение. Развитие технологий искусственного интеллекта (ИИ), машинного обучения (ML), искусственных нейронных сетей (ИНС), в частности глубоких, обуславливают широкие возможности их внедрения в различные сферы производства, в частности, в сельское хозяйство. Ведутся многочисленные исследования и разработки в сферах использования ИНС в роботах для сборки урожая [1], управлении теплицами методами искусственного интеллекта, обработки спутниковых изображений почв, рельефа, сельскохозяйственных полей. Возможно применение ИНС для выявления неявных закономерностей формирования урожаев [4] и других прикладных задач информационно-интеллектуальной поддержки аграрных исследований.

Большинство современных методов прогнозирования урожайности сельскохозяйственных культур основано на использовании вегетационных индексов типа NDVI или аналогов. В частности, такие подходы исследуют ученые В. П. Якушев, В. М. Буре, О. А. Митрофанова, Е. П. Митрофанов, А. Ф. Петрушин, С. Ю. Блохина, В. В. Якушев («Оценка внутриполевой изменчивости посевов с помощью вариограммного анализа спутниковых данных для точного земледелия») и др. Учеными изучаются возможности оценки характера и степени влияния на урожайность почвенно-климатических, агрометеорологических и других аспектов, включая показатели вегетационных индексов, дистанционно получаемые в различных диапазонах спектров отражения растениями (Черепанов А. С., Дружинина Е. Г. Спектральные свойства растительности и вегетационные индексы // Геоматика. 2009. № 3. С. 28–32.). Современные ИТ позволяют проводить анализ и выявлять роль конкретных факторов и их групп (<https://colab.research.google.com/drive/1Qsy-mZijkJ5aukCpbIA6EKMjh34N3eUl>), влияющих на урожайность культур и продуктивность земель, уточнять нормативы минерального питания и мелиорантов с учетом севооборотов, что позволяет выявить закономерностей формирования урожая (Лачуга Ю. Ф. Точное земледелие является перспективным направлением развития сельскохозяйственного производства в XXI веке // Машинные технологии производства продукции в системе точного земледелия и животноводства. М.: ГНУ ВИМ, 2005.). Также ведутся разработки по использованию нейросетей (ИНС) в сельском хозяйстве (José Padarian B.M.A.A.B.M. Using deep learning for Digital Soil Mapping), где оценивается качество почвы на основе свёрточной нейросети.

Известны опубликованные результаты исследования по обнаружению плодов садовых деревьев с использованием ИНС моделей ResNext, AlexNet, R-CNN и их комбинаций, алгоритмов YOLO и их модификаций [18].

Материалы и методы. Цель разработки – создание и исследование облачного сервиса SaaS для выявления дефектных участков сельскохозяйственных полей на основе искусственной нейронной сети.

Для достижения поставленной цели были сформулированы следующие задачи:

1. Обосновать архитектуру и разработать классификационную нейронную сеть.
2. Разработать серверную часть приложения.
3. Разработать пользовательскую часть приложения.

Изначальный датасет состоял из 250 картинок, что крайне мало для качественного обучения нейронной сети.

Для увеличения исходного датасета использовались различные методы аугментации данных, а именно:

1. Зеркальное отображение изображения.
2. Изменения угла наклона изображения в 90, 180 и 270 градусов.
3. Изменение масштаба.

Другой способ, который позволил расширить датасет, – это добавление в него некорректно распознанных изображений из тех, что в него изначально не входили. Итоговый размер датасета составил $6,5 \times 10^3$ изображений.

Особенностью архитектуры разработанного клиент-сервисного приложения явилось использование нейросетевого модуля на стороне сервера.

Для ускорения процесса обучения производилось на GPU с использованием технологии CUDA. Это было реализовано благодаря использованию GPU на базе чипа Nvidia RTX 2080ti, библиотеки CUDA Toolkit 11.4 и фреймворка Pytorch, который поддерживает работу с библиотекой.

Рисунок 1 – Укрупнённая структура нейронной сети ResNext

Figure 1 – The enlarged structure of the neural network of the Res Next model

Рисунок 2 – Исходное цветное изображение высокого разрешения фрагмента поля

Figure 2 – The original high-resolution color image of the field fragment

Результаты. *Архитектура разрабатываемой сети.* В качестве архитектуры была выбрана ResNext101x16. Предварительно были проведены тесты на ResNext101x8 и ResNext101x32. ResNext101x8 давала меньшую точность, а ResNext101x32, не увеличивая точность, замедляла алгоритм обучения. Другие архитектуры не рассматривались в рамках разработки прототипа.

Особенность архитектуры ResNext заключается в том, что обучение свёрточных слоев и объединение исходных данных блока слоёв сети с его результатом происходит параллельно (рисунок 1).

Рисунок 3 – Схема параметров свёрточного слоя

Figure 3 – Diagram of convolutional layer parameters

Свёрточный слой будет применять оператор свертки ко всем изображениям на входном тензоре, а также преобразовывать глубину ввода, чтобы соответствовать количеству фильтров [16].

N: Размер партии (Количество изображений в 4-мерном тензоре).

F: количество фильтров в слое свертки.

kW / kH: ширина / высота ядра.

H / W: высота / ширина изображения (обычно $H = W$).

H' / W': высота / ширина свернутого.

Stride: количество пикселей, которое будет перемещать скользящее окно свертки.

Отступы: к границе изображения добавлены нули, чтобы сохранить одинаковый размер входных и выходных данных.

Глубина: Глубина входного объема (т. е. Если входной сигнал является глубиной изображения RGB, будет равен 3).

Глубина вывода: Глубина вывода объема (такая же, как F).

Свёрточный слой является основным строительным блоком сверточной сети, которая выполняет большую часть вычислительной работы [14].

Fully Connected Layer. Данный слой является базисным слоем нейросетей. Он содержит веса нейросети.

Рисунок 4 – Схема параметров полносвязного FC слоя

Figure 4 – Diagram of the parameters of a fully connected FC layer

Входные данные представляют собой 4-х мерный тензор. Тензор состоит из измерений:

H – высота

W – ширина

Depth – глубина

Размер партии

На прямом распространении

1. Имеет 3 входа (входной сигнал, вес, смещение)

2. Имеет 1 выход

На обратном распространении

1. Имеет 1 вход (выход), который имеет тот же размер, что и выход;

2. Имеет 3 выхода (dx, dw, db).

Слой с функцией активации ReLU будет применять соответствующее преобразование ко всем элементам входного тензора, не изменяя его пространственную информацию или информацию о глубине.

Функции активации нейронов ReLU имеют следующие особенности:

- Легкость вычисления (прямое / обратное распространение)
- Меньшее влияние эффекта исчезающего градиента на глубоких моделях

Слабой стороной такой архитектуры является то, что нейроны могут необратимо «умереть», если используется слишком большая скорость обучения, задаваемая величиной шага оптимизатора.

Обучение разработанной CNN. Обучение разработанной CNN производилось с использованием языка Python и фреймворка Pytorch.

Обучение происходило на предварительно обученной модели на ImageNet путём переобучения классификатора. Классы для обучения были выбраны:

1. Хорошее поле

2. Проблемное поле

3. Незасаженное поле или не поле

Размер изображения исходного изображения составляет 255x255px. Обучение происходило на предобученной модели, поэтому изменить ее разрешение не было возможности.

В качестве оптимизатора был выбран алгоритм Adam. Шаг для обучения был выбран 0.003. Также были проверены шаги в разбросе от 0.001 до 0.1, наиболее успешными был вариант на 0.003, при меньшем значении требовалось больше эпох обучения, при большем – сеть быстро уходила в оверфит.

Рисунок 5 а) Обучение с Adam 0,001 б) Обучение с Adam 0,003 в) Обучение с Adam 0.01

Figure 5 a) Training with Adam 0,001 b) Training with Adam 0,003 c) Training with Adam 0.01

Для ускорения процесса обучения производилось на GPU с использованием технологии CUDA.

Результатом работы сети является класс для изображения размером 255x255. Но исходные изображения — это снимки полей размером в несколько тысяч на несколько тысяч пикселей, поэтому нарезаем изображение на части по 300 px и распознаём по отдельности, затем формируем слой-маску (рисунок 3) и накладываем его на исходное изображение (рисунок 4).

Архитектура разработанного приложения. Архитектура разработанного приложения включала серверную и клиентскую части. Серверная часть предусматривала:

1. REST и web-socket API для взаимодействия клиента с нейросетью.
2. Отдача статичных файлов на клиент (вёрстка, стили, скрипты).

REST (Representational State Transfer) – архитектурный стиль взаимодействия компонентов распределённого приложения в сет.

API (application programming interface) – описание способов, которыми одна компьютерная программа может взаимодействовать с другой программой.

Web-sockets – протокол связи поверх TCP-соединения, предназначенный для обмена сообщениями между браузером и веб-сервером в режиме реального времени.

Node.js – это JavaScript – окружение построенное на движке Chrome V8.

В качестве технология для реализации были использованы:

1. Python – для взаимодействия с сетью.
2. node.js – для ssr.
3. web-sockets как дополнительная технология обмена данными с клиентом.

Клиентская часть реализована, как SPA на React js + Redux. «Общение» с сервером организовано через web-sockets в качестве middleware для Redux. Использование web-sockets обусловлено отображением прогресса обработки в реальном времени.

SPA (single page application) – это веб-приложение или веб-сайт, использующий единственный HTML-документ как оболочку для всех веб-страниц и организующий взаимодействие с пользователем через динамически подгружаемые HTML, CSS, JavaScript, обычно посредством AJAX.

React.js – JavaScript-библиотека с открытым исходным кодом для разработки пользовательских интерфейсов.

Redux – библиотека для JavaScript [7] с открытым исходным кодом, предназначенная для управления состоянием приложения.

Рисунок 6 – Результат работы сети

Figure 6 – The result of the network

Использование классификационной сети показало, что нейросети способны решать задачи по распознаванию состояния полей. Сравнение полученных результатов с предыдущими версиями позволило выявить 10 % прироста точности. Также результатом является сервис, с которым могут взаимодействовать пользователи.

Выводы. Проведенные исследования позволили сформулировать следующие выводы:

1. Использование разработанной классификационной ИНС показало, что нейросети способны успешно решать задачи по распознаванию состояния сельскохозяйственных полей с выявлением дефектных участков различной природы.
2. Современные инфокоммуникационные технологии позволяют реализовать нейросетевые вычисления в облаке с обеспечением удобного масштабирования вычислительных мощностей.
3. Облачный сервис можно реализовать и монетизировать как SaaS.

Библиографический список

1. Кузнецова А. А., Малева Т. В., Соловьев В. И. Применение сверточных нейронных сетей для обнаружения плодов роботами для сбора урожая // Международный сельскохозяйственный журнал. 2020. Т. 63. № 5 (377). С. 39-41.
2. Рогачев А. Ф., Мелихова Е. В., Плещенко Т. В. Нейросетевая система управления программируемым аграрным производством с использованием ретроспективных данных и результатов дистанционного зондирования: монография. Волгоград: ФГБОУ ВО Волгоградский ГАУ, 2021. 172 с.
3. Bechar A., Vigneault C. Agricultural robots for field operations: Concepts and components // Biosystems Engineering. 2016. V. 149. P. 94-111.
4. Context-sensitive image analysis for coloring nature images / A. V. Alekseev [et al.] // Advances in Intelligent Systems and Computing. 2016. V. 451. P. 133-141.
5. He K. Mask R-CNN // Proceedings of the 2017 IEEE International Conference on Computer Vision — ICCV 2017. Venice, Italy, 2017. Pp. 2980-2988.
6. He K. Deep residual learning for image recognition // Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition — CVPR 2016. Las Vegas, Nevada, USA, 2016. Pp. 770-778.
7. Hidenori Ide, Takio Kurita Improvement of learning for CNN with ReLU activation by sparse regularization // International Joint Conference on Neural Networks (IJCNN), 2017.
8. Improved kiwifruit detection using pre-trained VGG16 with RGB and NIR information fusion / Z. Liu [et al.] // IEEE Access. 2020. Vol. 8. Pp. 2327-2336.
9. Kujawa S., Niedbała G. Artificial Neural Networks in Agriculture // Agriculture. 2021. V. 11(6). P. 497.
10. Mureşan H., Oltean, M. Fruit recognition from images using deep learning // Acta Universitatis Sapientiae. Informatica. 2018. Vol. 10. No. 1. Pp. 26-42.
11. Ren S. Faster RCNN: Towards real-time object detection with region proposal networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2017. Vol. 39. No. 6. Pp. 1137-1149.
12. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions / Laith Alzubaidi [et al.] // Journal of Big Data. 2021. V. 8. N. 53.
13. Robotic kiwifruit harvesting using machine vision, convolutional neural networks, and robotic arms / H. A. M. Williams [et al.] // Biosystems Engineering. 2019. Vol. 181. Pp. 140-156.
14. Rogachev A. F., Melikhova E. V., Belousov I. S. A set of data on retrospective grain yield for neural network modeling // IOP Conference Series: Earth and Environmental Science. 2021. V. 577. <https://iopscience.iop.org/article/10.1088/1755-1315/577/1/012006>.
15. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // Proceedings of the International Conference on Learning Representations — ICLR 2015. San Diego, California, USA, 2015. P. 1-14.

16. Smirnov E. A., Timoshenko D. M., Andrianov S. N. Comparison of regularization methods for imagenet classification with deep convolutional neural networks. 2014. Vol. 6. Iss. 1. P. 89-94.
17. Tereliansky P. V., Rogachev A. F., Melikhova E. V. Learning of Convolutional Neural Networks in the Tasks of Land Use Digitization Based on CUDA Technologies // *Socio-economic Systems: Paradigms for the Future. Studies in Systems, Decision and Control*. 2021. V. 314.
18. Three-Dimensional ResNeXt Network Using Feature Fusion and Label Smoothing for hyperspectral Image Classification / P. Wu [et al.] // *Sensors*. 2020. V. 20. P. 1652.

Conclusions.

The conducted studies allowed us to formulate the following conclusions.

1. The use of the developed classification INS has shown that neural networks are able to successfully solve problems of recognizing the state of agricultural fields with the identification of defective areas of various nature.
2. Modern information and communication technologies allow implementing neural network computing in the cloud with convenient scaling of computing power.
3. The cloud service can be implemented and monetized like SaaS.

References

1. Kuznetsova A. A., Maleva T. V., Soloviev V. I. Application of convolutional neural networks for fruit detection by robots for harvesting // *International Agricultural Journal*. 2020. V. 63. No. 5 (377). P. 39-41.
2. Rogachev A. F., Melikhova E. V., Pleshchenko T. V. Neural network control system for programmable agricultural production using retrospective data and remote sensing results: monograph. Volgograd: Volgograd State Agrarian University, 2021. 172 p.
3. Bechar A., Vigneault C. Agricultural robots for field operations: Concepts and components // *Biosystems Engineering*. 2016. V. 149. P. 94-111.
4. Context-sensitive image analysis for coloring nature images / A. V. Alekseev [et al.] // *Advances in Intelligent Systems and Computing*. 2016. V. 451. P. 133-141.
5. He K. Mask R-CNN // *Proceedings of the 2017 IEEE International Conference on Computer Vision — ICCV 2017. Venice, Italy, 2017*. Pp. 2980-2988.
6. He K. Deep residual learning for image recognition // *Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition — CVPR 2016. Las Vegas, Nevada, USA, 2016*. Pp. 770-778.
7. Hidenori Ide, Takio Kurita Improvement of learning for CNN with ReLU activation by sparse regularization // *International Joint Conference on Neural Networks (IJCNN)*, 2017.
8. Improved kiwifruit detection using pre-trained VGG16 with RGB and NIR information fusion / Z. Liu [et al.] // *IEEE Access*. 2020. Vol. 8. Pp. 2327-2336.
9. Kujawa S., Niedbała G. Artificial Neural Networks in Agriculture // *Agriculture*. 2021. V. 11(6). P. 497.
10. Mureşan H., Oltean, M. Fruit recognition from images using deep learning // *Acta Universitatis Sapientiae. Informatica*. 2018. Vol. 10. No. 1. Pp. 26-42.
11. Ren S. Faster RCNN: Towards real-time object detection with region proposal networks // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. Vol. 39. No. 6. Pp. 1137-1149.
12. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions / Laith Alzubaidi [et al.] // *Journal of Big Data*. 2021. V. 8. N. 53.
13. Robotic kiwifruit harvesting using machine vision, convolutional neural networks, and robotic arms / H. A. M. Williams [et al.] // *Biosystems Engineering*. 2019. Vol. 181. Pp. 140-156.
14. Rogachev A. F., Melikhova E. V., Belousov I. S. A set of data on retrospective grain yield for neural network modeling // *IOP Conference Series: Earth and Environmental Science*. 2021. V. 577. <https://iopscience.iop.org/article/10.1088/1755-1315/577/1/012006>.

15. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // Proceedings of the International Conference on Learning Representations — ICLR 2015. San Diego, California, USA, 2015. P. 1-14.

16. Smirnov E. A., Timoshenko D. M., Andrianov S. N. Comparison of regularization methods for imagenet classification with deep convolutional neural networks. 2014. Vol. 6. Iss. 1. P. 89-94.

17. Tereliansky P. V., Rogachev A. F., Melikhova E. V. Learning of Convolutional Neural Networks in the Tasks of Land Use Digitization Based on CUDA Technologies // Socio-economic Systems: Paradigms for the Future. Studies in Systems, Decision and Control. 2021. V. 314.

18. Three-Dimensional ResNeXt Network Using Feature Fusion and Label Smoothing for Hyperspectral Image Classification / P. Wu [et al.] // Sensors. 2020. V. 20. P. 1652.

Ilya S. Belousov, postgraduate, Department of Mathematical Modeling and Informatics, Volgograd State Agrarian University (26 Universitetskiy Ave., Volgograd, 400002, Russian Federation), <https://orcid.org/0000-0003-4415-8742>, neznaukaknazvatmail@gmail.com

Alexey F. Rogachev, Professor, Department of Mathematical Modeling and Informatics, Volgograd State Agrarian University (26 Universitetskiy Ave., Volgograd, 400002, Russian Federation), Doctor of Technical Sciences, Professor <https://orcid.org/0000-0001-6483-6091>, rafr@mail.ru

Информация об авторах

Белюсов Илья Станиславович, аспирант кафедры «Математическое моделирование и информатика» Волгоградского государственного аграрного университета (РФ, 400002, г. Волгоград, пр-т Университетский, д. 26) <https://orcid.org/0000-0003-4415-8742>, neznaukaknazvatmail@gmail.com

Рогачев Алексей Фруминович, профессор кафедры «Математическое моделирование и информатика» Волгоградского государственного аграрного университета (РФ, 400002, г. Волгоград, пр-т Университетский, д. 26), доктор технических наук, профессор <https://orcid.org/0000-0001-6483-6091>, rafr@mail.ru

DOI: 10.32786/2071-9485-2021-03-46

THE QUESTION OF PLANNING AND CONDUCTING OF LOCAL STUDIES OF DIFFUSE POLLUTION OF WATER OBJECTS

A.V. Slabunova, A. P. Surovikina, E. V. Komarova

Federal State Budget Scientific Institution

«Russian Research Institute of Melioration Problems», Novocherkassk

Received 28.04.2021

Submitted 23.08.2021

Abstract

Introduction. The purpose of the study is to determine the main criteria for planning and conducting field studies in the study of diffuse pollution of water objects in areas of intensive agricultural activity. **Object.** The object of the study was the manifestation of diffuse pollution of the drainage areas of water objects in the zones of intensive agricultural activity. **Materials and methods.** The methodology of the proposed plan for carrying out full-scale (field) studies of diffuse pollution of water objects is based on the results of research works of the authors who previously studied this problem, and the regulatory aspect. The method of systematic analysis, comparison and generalization of data was used.

Results and conclusions. The article presents: a set of main tasks solved during field research, and a general plan of work in the study of diffuse pollution of water objects from catchment areas in areas of intensive agricultural activity, covering all the features, manifestations and factors that determine diffuse pollution. It has been established that most of the pollutants from the catchment area enter the water object with diffuse runoff caused by water erosion. The main negative load of diffuse pollution falls on small rivers with agricultural land in the catchment area. Today, the problem of accounting for the uncontrolled intake of pollutants into a water object is the lack of full, reliable information on the mechanism of diffuse pollution. In this regard, it is necessary to fully study the features and nature of diffuse pollution of water objects in zones of intensive agricultural activity in accordance with the established criteria: the complexity of research (observations are carried out in the «catchment + water object» complex), taking into account the frequency of manifestation of diffuse pollution water objects, taking into account the spatial distribution of diffuse pollution in the catchment area of a water object.