



МАТЭМАТЫКА

УДК 004.8:004.93

ИСПОЛЬЗОВАНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ КЛАССИФИКАЦИИ В НЕКОНТРОЛИРУЕМЫХ УСЛОВИЯХ

Н.Д. Никонов*, Т.В. Никонова**, О.Е. Рубаник**, Е.А. Корчевская ***

**Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет ИТМО»*

***Учреждение образования «Витебский государственный технологический университет»*

****Учреждение образования «Витебский государственный университет имени П.М. Машерова»*

Актуальность рассматриваемого вопроса обусловлена тем, что выявление и лечение заболеваний растений – один из самых основных и важных видов деятельности в сельском хозяйстве.

Цель статьи – описание методики повышения точности в неконтролируемых условиях при решении задач классификации заболеваний растений у популярных моделей нейронных сетей и исследование факторов среды, наиболее значительно влияющих на точность модели.

Материал и методы. *В качестве материала используем несколько наборов данных – PlantVillage Dataset, PlantDoc и Cropped-PlantDoc. При выполнении исследования находят применение архитектуры сверточных нейронных сетей: Inception-v3, VGG16, VGG13.*

Результаты и их обсуждение. *Из результатов, полученных при тестировании на наборе данных Cropped-PlantDoc, можно сделать вывод, что сети, обученные только на PlantVillage Dataset, в реальных полевых условиях показывают себя значительно хуже. Модель дает неточные результаты из-за фонового шума, не строго ориентированного расположения листа, его деформаций.*

Сети, обученные на наборах PlantVillage Dataset и Cropped-PlantDoc, к которым был применен метод увеличения данных, показали значительно лучший результат при тестировании на наборе Cropped-PlantDoc.

Заключение. *Предложенный подход основан на использовании архитектур CNN, таких как VGG13, VGG16 и InceptionV3, и тестировании этих моделей на наборе данных Cropped-PlantDoc. Показано, что, обучая модели на наборе Cropped-PlantDoc, можно достигнуть значительно большей точности при применении приложения в полевых условиях.*

Ключевые слова: *машинное обучение, сверточные нейронные сети, задача классификации, болезни растений.*

USING CONVOLUTIONAL NEURAL NETWORKS IN SOLVING PROBLEMS OF CLASSIFICATION IN UNCONTROLLED CONDITIONS

N.D. Nikonov*, T.V. Nikonova**, O.E. Rubanik**, E.A. Korchevskaya ***

*Federal State Autonomous Higher Education Establishment "National ITMO Research University"

**Education Establishment "Vitebsk State Technological University"

***Education Establishment "Vitebsk State P.M. Masherov University"

The research relevance is due to the fact that identification and treatment of plant diseases is one of the basic and most significant activities in agriculture.

The research purpose is a description of the methods of the accuracy improvement in uncontrolled conditions in solving problems of plant disease classification by popular models of neural networks as well as a study of the environment factors which influence considerably the accuracy of the model.

Material and methods. *A number of data sets, PlantVillage Dataset, PlantDoc and Cropped-PlantDoc, were used as research material. Architectures of convolutional neural networks Inception-v3, VGG16, VGG13 were applied in the research.*

Findings and their discussion. *The findings received from testing Cropped-PlantDoc set of data make it possible to conclude that networks which are trained only on PlantVillage Dataset are considerably worse in real field conditions. The model in inaccurate due to background noise, nor strictly oriented position of the leaf, its deformations. Networks trained on the sets of PlantVillage Dataset and Cropped-PlantDoc, to which the method of data enlargement was applied, manifested a considerably better result in Cropped-PlantDoc set testing.*

Conclusion. *The proposed approach is based on the application of CNN architectures such as VGG13, VGG16 and InceptionV3 and on the testing of these models on Cropped-PlantDoc data set. It is demonstrated that by training the models on Cropped-PlantDoc set it is possible to obtain a considerably larger accuracy in applying the application in field conditions.*

Key words: *machine training, convolutional neural networks, classification problem, plant diseases.*

Глубокие нейронные сети успешно используются в агрохозяйствах для борьбы с основными угрозами продовольственной безопасности [1–3]. Болезни растений всегда являются одной из насущных проблем, поскольку они резко снижают урожайность сельскохозяйственных культур и ухудшают их качество. Выявление и лечение заболеваний растений – значимый вид деятельности в аграрной отрасли. Традиционно идентификация болезней растений осуществлялась людьми путем визуального осмотра, но подобный метод идентификации диагностики подвержен ошибкам. С другой стороны, лабораторные анализы, такие как молекулярные, иммунологические или подходы, основанные на культивировании патогенов, часто требуют много времени и не дают быстрых ответов. Сочетание растущего глобального распространения мобильных устройств и последних достижений в области компьютерного зрения сделало возможным выполнять своевременно диагностику заболеваний. Комбинирование технологий обработки изображений, телекоммуникаций и вычислительных мощностей в новых моделях смартфонов открыло множество возможностей для их применения в качестве диагностических инструментов, которые могут практически мгновенно фиксировать, отображать и передавать результаты. Изображения симптомов затем отправляются через сеть Интернет на платформу, где специалисты могут поставить диагноз. Альтернативная стратегия основана на методах искусственного интеллекта и машинного обучения, которые позволяют непосредственно обнаруживать и идентифицировать вредителей на месте.

Цель статьи – описание методики повышения точности в неконтролируемых условиях при решении задач классификации заболеваний растений у популярных моделей нейронных сетей и изучение факторов среды, значительно влияющих на точность модели.

Материал и методы. В исследовании используются успешно показавшие себя архитектуры сверточных нейронных сетей (CNN), разработанных для классификации изображений, обнаружения объектов, семантической и интерактивной сегментации: Inception-v3, VGG16, VGG13 [4]. Применен и метод построения карт внимания для решения проблемы «черного ящика» [5], подтвердивший, что при совместном использовании сети и визуальном осмотре специалистом карты внимания можно добиться высокой точности классификации [6].

В нашей работе мы применяем несколько наборов данных – PlantVillage Dataset (PVD) [7], PlantDoc [8] и созданный нами Cropped-PlantDoc (C-PD). Осенью 2019 года исследователи Индийского технологического института выпустили PlantDoc – набор данных из 2598 изображений 13 видов растений и 27 классов (17 болезней; 10 здоровых) для классификации изображений и обнаружения внешних признаков заболеваний. Этот набор изображений примечателен тем, что содержит снимки растений, максимально приближенные к полевым, в отличие от PlantVillage Dataset, который был создан в контролируемых условиях. В неконтролируемых условиях такие факторы, как погодные условия (солнечный свет, ветер, туман и дождь), качество фото и фон, оказывают сильное влияние на точность диагностической системы. Поэтому для проведения экспериментов мы использовали набор данных Cropped-PlantDoc. Он был получен путем обрезки изображений, содержащих несколько листовых пластинок набора данных PlantDoc, для получения изображений, имеющих только одну пораженную листовую пластинку (рис. 1). Таким образом, мы получили Cropped-PlantDoc, содержащий 8468 изображений (13 видов сельскохозяйственных культур и 17 видов заболеваний). Изображения были разделены на обучающие, валидационные наборы данных в соотношении 8:2. PlantVillage Dataset – набор данных из 54306 изображений листьев растений (26 видов заболеваний, 14 видов сельскохозяйственных культур). Изображения были разделены на обучающие, валидационные и тестовые наборы данных с соотношением 8:1,5:0,5.



Рис. 1. Пример нарезки исходного изображения из набора данных PlantDoc на несколько, содержащих только одну листовую пластину

Результаты и их обсуждение. Работа посвящена выявлению и распознаванию болезней, поражающих растения томатов. Томат был выбран для изучения, т.к. он является экономически важной овощной культурой во всем мире. Рассмотрено 6 видов наиболее распространенных заболеваний томата, поэтому данные разделены на 7 классов (седьмой класс – это здоровые растения). Количество изображений, соответствующее каждому классу в наборах данных PVD и C-PD, представлено в табл. 1. Каждому заболеванию присущи характерные признаки, показанные на рис. 2.

Для обучения сверточных нейронных сетей использован алгоритм оптимизации Adam [9]: categorical crossentropy loss и шаг обучения, равный 0,001, размер батча 32. Во всех подходах размер изображений изменялся до 150×150 пикселей для увеличения производительности без особой потери качества изображения. Для оценки производительности моделей были выбраны метрики на основе Confusion matrix (F1-score и Accuracy).

Модели, которые были обучены с нуля, показывали более медленный прирост точности по сравнению с предобученными моделями при одинаковом количестве эпох. Поэтому для ускорения процесса обучения применялся метод переноса обучения и использовались модели, которые были предварительно обучены на наборе ImageNet.

Распределение изображений по классам

Номер класса	Класс	Количество снимков в PVD	Количество снимков в C-PD
0	Tomato Bacterial spot	2126	287
1	Tomato Early blight	31000	222
2	Tomato Late blight	1908	226
3	Tomato Leaf Mold	950	292
4	Tomato Septoria leaf spot	1769	444
5	Tomato Yellow Leaf Curl Virus	3208	844
6	Tomato healthy	1589	402



Рис. 2. Внешние признаки, характерные для каждого класса заболевания (0 – Tomato Bacterial spot, 1 – Tomato Early blight, 2 – Tomato Late blight, 3 – Tomato Leaf Mold, 4 – Tomato Septoria leaf spot, 5 – Tomato Yellow Leaf Curl Virus)

Все рассматриваемые модели CNN, обученные на наборе данных PlantVillage, при последующем тестировании на нем, продемонстрировали хороший результат (Accuracy 95% и выше). Из результатов (табл. 2), полученных при тестировании на наборе данных Cropped-PlantDoc, можно сделать вывод, что сети, обученные только на PlantVillage, в реальных полевых условиях показывают себя значительно хуже. Модель дает неточные результаты из-за фонового шума, не строго ориентированного расположения листа, его деформаций и прочих факторов, вызванных внешними условиями (погода, неравномерная освещенность листа) или низким качеством фото.

Для увеличения набора данных, борьбы с переобучением и улучшения обобщающей способности наших моделей мы применили стандартные методы увеличения данных, такие как вращение, горизонтальный и вертикальный перенос, масштабирование. Кроме этого, использовалось добавление шума, изменение яркости, цвета и контраста, которые могут имитировать различные погодные условия (солнце, ветер, туман) или размытую фотографию, сделанную непрофессиональным фотографом.

Параметры аугментации: угол поворота – 180, повышение яркости фото равномерно и в пределах от 0,9 до 1,1, смещение по горизонтальной и вертикальной осям – 0,2, отдаление – 0,2. Сети, обученные на наборах PlantVillage Dataset и Cropped-PlantDoc (80%), к которым был применен метод увеличения данных, достигли значительно лучшего результата при тестировании на наборе Cropped-PlantDoc. В наборе с 7 классами шанс «случайно угадать» класс заболевания равен 14,2%. В табл. 2 представлены архитектуры сетей, участвовавшие в экспериментах, и соответствующие им значения F1-score, Accuracy. Наилучшую точность в задаче классификации на наборе C-PD (20%) показала архитектура Inceptionv3, обученная на C-PD (80%) (Accuracy 71,43%), в то же время архитектуры VGG13 и VGG16 достигли на этом же наборе данных средней точности, равной 56,16% и 54,68%.

Таблица 2

Результаты экспериментов

Модель	Обучающий набор	Тестовый набор	Accuracy, %	F1-score
VGG13	PVD	PVD	98,1	0,98
VGG13	PVD	C-PD	25,42	0,24
VGG13	PVD+Data Aug.	C-PD	36,47	0,36
VGG13	C-Pd+Data Aug.	C-PD	56,16	0,56
VGG16	PVD	PVD	95,11	0,95
VGG16	PVD	C-PD	14,3	0,13
VGG16	PVD+Data Aug.	C-PD	22,97	0,22
VGG16	C-Pd+Data Aug.	C-PD	54,68	0,54
Inceptionv3	PVD	PVD	99,52	0,99
Inceptionv3	PVD	C-PD	30,86	0,30
Inceptionv3	PVD+Data Aug.	C-PD	42,36	0,41
Inceptionv3	C-Pd+Data Aug.	C-PD	71,43	0,71

При визуальном осмотре пораженных листьев растений у специалиста могут возникнуть затруднения при схожести внешних признаков заболевания. Например, схожесть симптомов при заболеваниях Bacterial spot и Septoria leaf spot продемонстрирована на рис. 3.



Рис. 3. Листы томата с заболеваниями Bacterial spot и Septoria leaf spot

Чтобы понять, как работает наша модель и что именно она изучает, мы реализовали два метода визуализации на обученной модели VGG13 с использованием набора данных PlantVillage Dataset для визуального объяснения классификационных решений системы: визуализацию промежуточных активаций модели на последнем сверточном слое [10], состоящую из отображения карт признаков,

которые строятся различными слоями свертки, и построение карт внимания (Grad-CAM) [11]. Выходные данные Grad-CAM – это визуализация тепловой карты для данной метки класса. Эти методы также можно применять для решения проблемы «черного ящика» и помощи специалистам при визуальной идентификации болезни растений. Карты внимания (Grad-CAM) дают представление о том, какие части фотографии являются определяющими для сети при классификации заболеваний.

Также они могут дать информацию, почему диагностическая система ошиблась и какой фактор привел к подобной ошибке. Все получившиеся результаты отображены на рис. 4. По результатам построенных визуализаций промежуточных активаций модели заметно, что наша диагностическая система научилась определять форму листа, что при необходимости поможет ей различать виды растений, но этого недостаточно для полного понимания, какие части фото оказали наибольшее влияние на сеть. Однако в случае с картами внимания (Grad-CAM) видно, что наша нейронная сеть научилась фокусироваться на наборе визуальных признаков, которые характерны для определенных болезней.

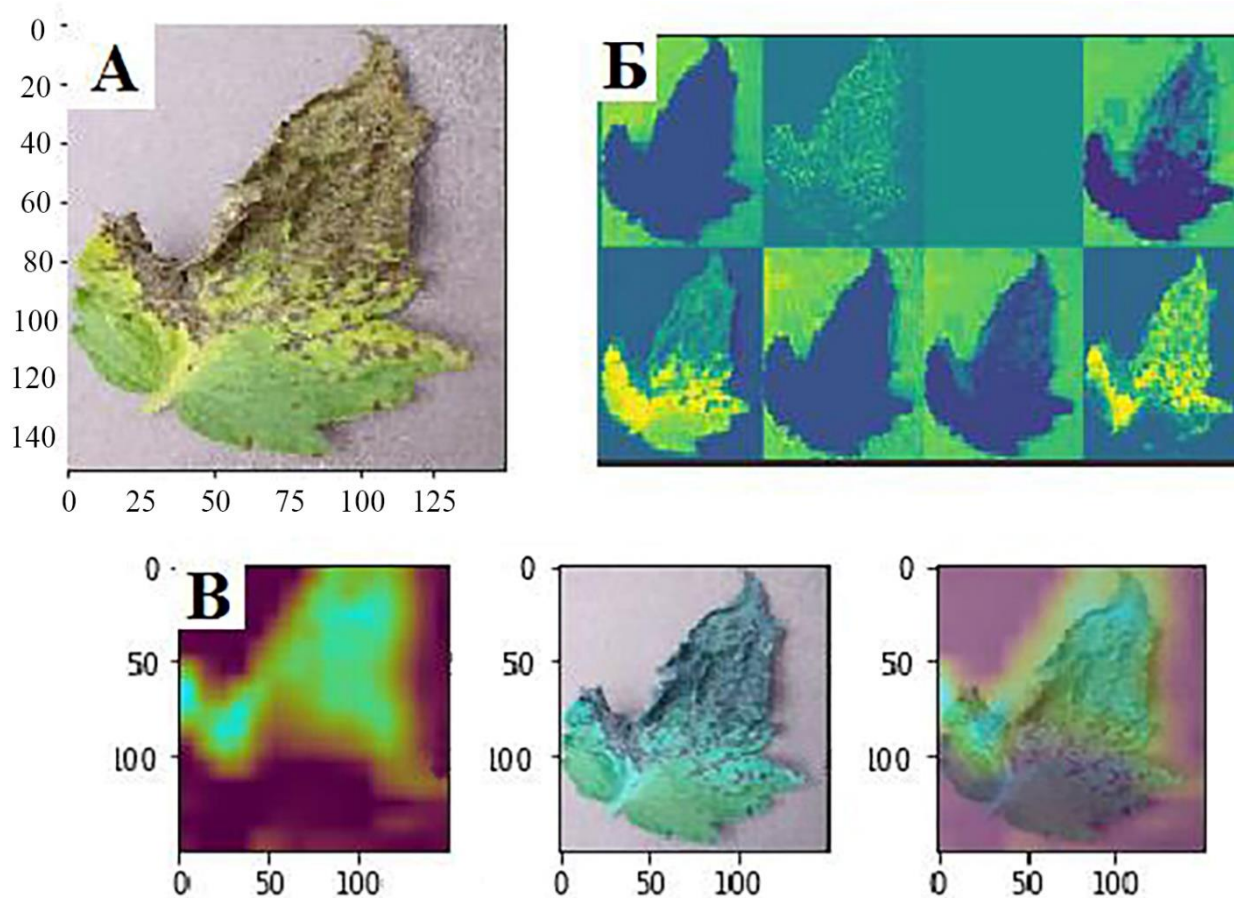


Рис. 4. А – изображение листовой пластинки, зараженной *Tomato Septoria leaf spot* в поздней стадии, Б – визуализация промежуточных активаций модели, В – карта внимания (Grad-CAM)

Заключение. Предложенный подход основан на использовании успешно показавших себя архитектур CNN, таких как VGG13, VGG16 и InceptionV3, и тестировании этих моделей на более реалистичном наборе данных Cropped-PlantDoc, который был нарезан на основе набора данных PlantDoc Dataset. Мы обучили модели на изображениях листьев растений с целью классификации наличия и идентичности болезней на изображениях, которые модель ранее не видела, и продемонстрировали, что, обучая модели на наборе Cropped-PlantDoc, можно достигнуть значительно большей точности (71,43% Accuracy) при применении приложения в полевых условиях. PlantVillage Dataset используется для проведения экспериментов в большинстве научных работ, т.к. он является единственным общедоступным набором изображений заболеваний растений. Во многом проблему классификации заболеваний растений можно решить, если создать набор данных,

аналогичный PlantVillage Dataset, содержащий изображения растений с различными вариантами фона, освещения, видов заболеваний и углами, под которыми получен снимок.

К тому же, построив визуализацию промежуточных активаций модели и построение карт внимания (Grad-CAM), мы показали, что при совместном применении нашей сети и визуальном осмотре специалистом карты внимания можно добиться высокой точности классификации [6] и решить проблему «черного ящика».

В дальнейшем планируется провести исследование влияния внешних признаков на точность диагностической системы. Например, неоднородной освещенности (наличие бликов, неполная освещенность листа) или фона, для чего будет создан специальный набор данных. Полученные результаты будут использоваться в работе мобильного приложения, осуществляющего классификацию заболеваний томатов.

ЛИТЕРАТУРА

1. Никонов, Н.Д. Использование сверточных нейронных сетей для решения задач классификации болезней растений / Н.Д. Никонов // XV Машеровские чтения: материалы междунар. науч.-практ. конф. студентов, аспирантов и молодых ученых, Витебск, 22 окт. 2021 г.: в 2 т. / Витеб. гос. ун-т; редкол.: Е.Я. Аршанский (гл. ред.) [и др.]. – Витебск, 2021. – Т. 1. – С. 30–32.
2. Никонов, Н.Д. Разработка мобильного приложения для распознавания болезней томатов / Н.Д. Никонов, Т.В. Никонова // Молодежь. Наука. Творчество: материалы XIX Всерос. науч.-практ. конф., Омск, 9–11 нояб. 2021 г. / М-во образования и науки России [и др.]; редкол.: Е.Б. Юдин [и др.]. – Омск: Изд-во ОмГТУ, 2021. – С. 10–12.
3. Корчевская, Е.А. Использование сверточной нейронной сети для решения задачи классификации / Е.А. Корчевская, Л.В. Маркова, Т.В. Никонова // Вестн. Витеб. дзярж. ун-та. – 2022. – № 2(115). – С. 5–9.
4. Khan, A. A survey of the recent architectures of deep convolutional neural networks / A. Khan, A. Sohail, U. Zahoora [et al.] // Artif Intell Rev. – 2020. – № 53. – P. 5455–5516.
5. Yosuke, T. How Convolutional Neural Networks Diagnose Plant Disease [Electronic resource] / T. Yosuke, F. Okura // Plant Phenomics. – 2019. – Mode of access: <https://spj.sciencemag.org/journals/plantphenomics/2019/9237136>. – Date of access: 22.06.2022.
6. Çuğu, İ. Treelogy: A Novel Tree Classifier Utilizing Deep and Hand-crafted Representations [Electronic resource] / İ. Çuğu, E. Şener [et al.]. – 2017. – Mode of access: <https://arxiv.org/abs/1701.08291>. – Date of access: 22.06.2022.
7. Mohanty, S. Using Deep Learning for Image-Based Plant Disease Detection / S. Mohanty, D.P. Hughes, M. Salathé // Front Plant Sci. – 2016. – № 7. – P. 1419.
8. Singh, D. Plantdoc: A dataset for visual plant disease detection / D. Singh, N. Jain [et al.] // Proceedings of the 7th ACM IKDD CoDS and 25th COMAD, January 2020 / CoDS COMAD Hyderabad, India 2020. – P. 249–253.
9. Diederik, P.K. Adam: A Method for Stochastic Optimization [Electronic resource] / P.K. Diederik, J. Ba // The 3rd International Conference for Learning Representations. – San Diego, 2015. – Mode of access: <https://arxiv.org/abs/1412.6980>. – Date of access: 22.06.2022.
10. Jiang, Y. Convolutional Neural Networks for Image-Based High-Throughput Plant Phenotyping [Electronic resource] / Y. Jiang, Ch. Li // Plant Phenomics. – 2020. – Mode of access: https://pdfs.semanticscholar.org/bcc0/9a01e2f4115adb78e6585d7b148d854c6b7d.pdf?_ga=2.117860106.2000502033.1661160781-1489065728.1660738440. – Date of access: 22.06.2022.
11. Selvaraju, R.R. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization / R.R. Selvaraju, M. Cogswell, A. Das [et al.] // Int. J. Comput. Vis. – 2020. – № 128. – P. 336–359.

REFERENCES

1. Nikonov N.D. XV Masherovskie chteniya: materialy mezhdunar. nauch.-prakt. konf. studentov, aspirantov i molodykh uchenykh, Vitebsk, 22 okt. 2021 g. [Masherov Readings: Proceedings of the International Scientific and Practical of Students, Postgraduate Students and Young Scholars, Vitebsk, October 22, 2021], Vitebsk State University, Vitebsk, 2021, 1, pp. 30–32.
2. Nikonov N.D., Nikonova T.V. *Molodezh. Nauka. Tvorchestvo: materialy XIX Vseros. nauch.-prakt. konf., Omsk, 9–11 noyab. 2021 g.* [Youth. Science. Creativity: Proceedings of the XIX All-Russia Scientific and Practical Conference, Omsk, November 9–11, 2021], Omsk: Izd-vo OmGTU, 2021, pp. 10–12.
3. Korchevskaya E.A., Markova L.V., Nikonova T.V. *Vesn. Vitebs. dzyarzh. un-ta* [Bulletin of Vitebsk State University], 2022, 2(115), pp. 5–9.
4. Khan, A. A survey of the recent architectures of deep convolutional neural networks / A. Khan, A. Sohail, U. Zahoora [et al.] // Artif Intell Rev. – 2020. – № 53. – P. 5455–5516.
5. Yosuke, T. How Convolutional Neural Networks Diagnose Plant Disease [Electronic resource] / T. Yosuke, F. Okura // Plant Phenomics. – 2019. – Mode of access: <https://spj.sciencemag.org/journals/plantphenomics/2019/9237136>. – Date of access: 22.06.2022.
6. Çuğu, İ. Treelogy: A Novel Tree Classifier Utilizing Deep and Hand-crafted Representations [Electronic resource] / İ. Çuğu, E. Şener [et al.]. – 2017. – Mode of access: <https://arxiv.org/abs/1701.08291>. – Date of access: 22.06.2022.
7. Mohanty, S. Using Deep Learning for Image-Based Plant Disease Detection / S. Mohanty, D.P. Hughes, M. Salathé // Front Plant Sci. – 2016. – № 7. – P. 1419.
8. Singh, D. Plantdoc: A dataset for visual plant disease detection / D. Singh, N. Jain [et al.] // Proceedings of the 7th ACM IKDD CoDS and 25th COMAD, January 2020 / CoDS COMAD Hyderabad, India 2020. – P. 249–253.
9. Diederik, P.K. Adam: A Method for Stochastic Optimization [Electronic resource] / P.K. Diederik, J. Ba // The 3rd International Conference for Learning Representations. – San Diego, 2015. – Mode of access: <https://arxiv.org/abs/1412.6980>. – Date of access: 22.06.2022.
10. Jiang, Y. Convolutional Neural Networks for Image-Based High-Throughput Plant Phenotyping [Electronic resource] / Y. Jiang, Ch. Li // Plant Phenomics. – 2020. – Mode of access: https://pdfs.semanticscholar.org/bcc0/9a01e2f4115adb78e6585d7b148d854c6b7d.pdf?_ga=2.117860106.2000502033.1661160781-1489065728.1660738440. – Date of access: 22.06.2022.
11. Selvaraju, R.R. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization / R.R. Selvaraju, M. Cogswell, A. Das [et al.] // Int. J. Comput. Vis. – 2020. – № 128. – P. 336–359.

Поступила в редакцию 06.09.2022

Адрес для корреспонденции: e-mail: st.rubon@mail.ru – Никонова Т.В.