

Разработка алгоритма роботизированного устройства точного внесения средств защиты растений

Максим Арифович Мирзаев,
аспирант, младший научный сотрудник,
e-mail: mirza.pochta@gmail.com

Федеральный научный агроинженерный центр ВИМ, Москва, Российская Федерация

Реферат. Показали, что широкий спектр методик и инструментов для идентификации растений ограничен в реальных агротехнических задачах. Отметили, что параметры изображений сильно отличаются в прикладных решениях. (*Цель исследования*) Разработать алгоритм распознавания культурных растений роботизированным устройством, основанный на современном методе глубокого обучения с использованием сверточной нейронной сети R-CNN. (*Материалы и методы*) Создали роботизированное устройство для дифференцированного внесения средств защиты растений, которое способно распознавать полезную культуру и сорную растительность, определять площадь обработки по координатам центра и радиусу. Для обнаружения сельскохозяйственной культуры (белокочанной капусты) выбрали сегментирующие нейронные сети Mask R-CNN и Deeplabv3 plus. Алгоритм на основе данных сетей обнаруживает, сегментирует и позиционирует растения на основе набора данных, собранных в форматах «изображение – маска» и COCO dataset. Набор данных формировали путем аэросъемки с помощью беспилотного воздушного судна. Исходные изображения получили от веб-камеры Xiaovv HD Web USB с углом съемки 150 градусов, разрешением Full HD 1080P и веб-камеры Logitech C270 с разрешением HD 720p. Обученную нейронную сеть для роботизированного устройства установили на платформу Nvidia Jetson AGX Xavier. (*Результаты и обсуждение*) В результате оценки точности модели на тестовых данных получили следующие значения: количество найденных растений – 98 процентов, точность выделения контура – 94 процента. (*Выводы*) Доказали, что обученную нейронную сеть можно применять к любым выращиваемым культурам, учитывая неоднородность их расположения на поле, типы почвы, количество сорной растительности. По итогу модель обучили извлекать координаты ограничительной рамки и местоположение объекта (капусты) по пикселям с требуемой точностью как для синтетических, так и для реальных данных.

Ключевые слова: дифференцированное внесение средств защиты растений, обучение нейронной сети, Mask R-CNN, Deeplabv3 plus, точное земледелие, распознавание растений.

■ **Для цитирования:** Мирзаев М.А. Разработка алгоритма роботизированного устройства точного внесения средств защиты растений // *Сельскохозяйственные машины и технологии*. 2022. Т. 16. №3. С. 74-80. DOI 10.22314/2073-7599-2022-16-3-74-80. EDN JLDWMP.

Developing an Algorithm for Robotic Precision Application of Crop Protection Products

Maksim A. Mirzaev,
Ph.D. student, junior researcher,
e-mail: mirza.pochta@gmail.com

Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

Abstract. The existing range of plant identification methods and tools is considered limited in real agrotechnical tasks. The image parameters tend to differ significantly in applied solutions. (*Research purpose*) To develop an algorithm for crop plant recognition by a robotic device using a state-of-the-art convolutional neural network (R-CNN) and deep learning technology. (*Materials and methods*) A robotic device has been developed for variable rate application of plant protection products able to recognize both useful crops and weeds, determine the area of processing, namely the coordinates of the processing center and the processing radius. Mask R-CNN and Deeplabv3 plus segmenting neural networks were chosen for crop (white head cabbage) detection. The network-based algorithm detects, segments, and positions plants based on a dataset collected in the image-mask and COCO dataset formats. The data set was formed by aerial photography using an unmanned aircraft. The original images are taken by

Xiaovv HD Web USB 150 degree Full HD 1080P webcam and Logitech C270 HD 720p webcam. The trained neural network for the robotic device was installed on the Nvidia Jetson AGX Xavier platform. *(Results and discussion)* As a result of assessing the accuracy of the model on the test data, the following values were obtained: the number of plants detected is 98 percent, the accuracy of contour detection is 94 percent. *(Conclusions)* It is proved that the trained neural network can be applied to any cultivated crops, taking into account the heterogeneity of their location in the field, soil types, and the percentage of weeds. As a result, the model is trained to extract the bounding box coordinates and the object (cabbage) location by pixels with the required accuracy for both synthetic and real data.

Keywords: variable rate application of plant protection products, neural network training, Mask R-CNN, Deeplabv3 plus, precision farming, plant recognition.

For citation: Mirzaev M.A. Razrabotka algoritma robotizirovannogo ustroystva tochnogo vneseniya sredstv zashchity rasteniy [Developing an algorithm for robotic precision application of crop protection products]. *Sel'skokhozyaystvennyye mashiny i tekhnologii*. 2022. Vol. 16. N3. 74-80 (In Russian). DOI 10.22314/2073-7599-2022-16-3-74-80. EDN JLDWMP.

Широкий спектр методик и инструментов для идентификации растений ограничен в реальных агротехнических задачах. В абсолютном большинстве представленных решений важную роль играют параметры изображений, а они сильно отличаются в прикладных решениях. Зачастую в роботизированном устройстве расположение камер, освещение, параметры камеры и входные данные на алгоритм разнятся с существующими наборами данных для подобных задач. Поэтому актуальны сбор данных напрямую с роботизированного устройства и обучение алгоритма, специализированного под конкретную задачу. Разработанный алгоритм позволяет распознавать изображения культур и рассчитывать дозу внесения агрохимических средств, а также регулировать их расход в зависимости от площади опрыскивания.

Уже есть наработки по данному алгоритму на основе метода обработки контура. Однако качество этого алгоритма не превышает 90%, что неприемлемо для реальных задач, поскольку в работе задействованы нейронные сети.

Цель исследования – разработать алгоритм распознавания культурных растений роботизированным устройством, основанный на современном методе глубокого обучения с использованием сверточной нейронной сети *R-CNN*.

Материалы и методы. Роботизированное устройство для дифференцированного внесения средств защиты растений обеспечивает распознавание полезной культуры и сорной растительности, определяет площадь обработки по координатам центра и радиусу (рис. 1).

Основная задача роботизированного устройства при дифференцированном внесении – правильно определить площадь обработки.

Разработанный алгоритм позволяет распознавать изображения культур, рассчитывать дозу внесения агрохимических средств, регулировать их расход в зависимости от площади опрыскивания (рис. 2) [1].



Рис. 1. Автономный полевой робот для дифференцированного внесения агрохимических средств в полевых условиях
Fig. 1. Autonomous field robot for variable rate application of agrochemicals in the field

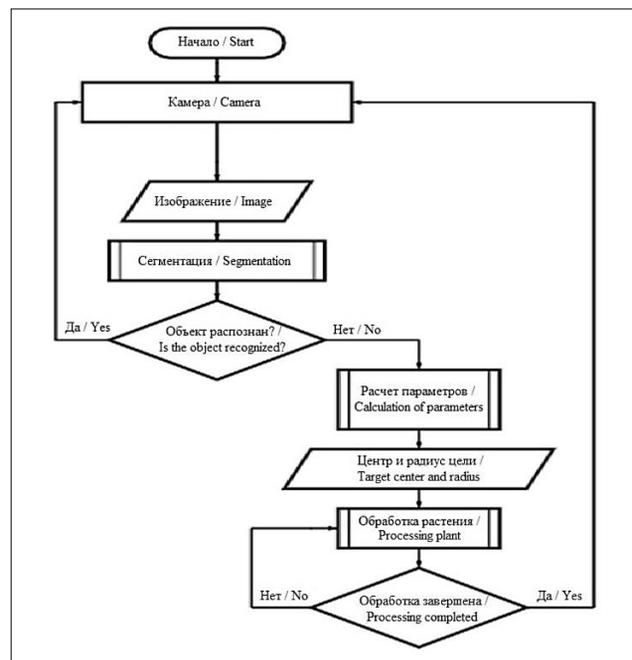


Рис. 2. Принцип работы алгоритма
Fig. 2. Algorithm operating principle

Для сегментации исходных изображений с камер Xiaovv HD Web USB с углом съемки 150° и разреше-

нием *Full HD 1080P* и веб-камеры *Logitech C270* с разрешением *HD 720p* за основу выбрали сегментирующие нейронные сети *Mask R-CNN* и *Deeplabv3 plus*.

Mask R-CNN представляет собой сверточную нейронную сеть (*CNN*) для сегментации изображений. Модель обнаруживает объекты на изображении и генерирует высококачественную маску сегментации для каждого экземпляра [2].

DeepLab – библиотека компьютерного зрения на *TensorFlow2*. Она предоставляет унифицированную и современную кодовую базу *TensorFlow* для задач плотной маркировки пикселей, включая, помимо прочего, семантическую сегментацию, сегментацию экземпляров, паноптическую сегментацию видео с учетом оценочного значения глубины каждого пикселя изображения [3].

Глубокая разметка относится к решению проблем компьютерного зрения путем присвоения прогнозируемого значения для каждого пикселя изображения с помощью глубокой нейронной сети. Модель *Panoptic-DeepLab* в составе библиотеки достигла 68,0% *PQ*, или 83,5% *mIoU* при проверке на датасете *Cityscapes* [4].

Поскольку роботизированное устройство движется с постоянной скоростью и необходимо обеспечить захват всей рабочей области, применили метод сшивания фото и видео в режиме реального времени.

Сшивание изображений и видео – процесс объединения нескольких фотографий/видео с перекрывающимися полями обзора для создания сегментированной панорамы или изображения/видео с высоким разрешением. Обычно его выполняют с использованием компьютерного программного обеспечения, позволяющего точно перекрыть изображения/видео для получения бесшовных результатов.

Для обучения нейронной сети использовали наборы данных в двух форматах – «изображение – маска» и *COCO dataset*. Подход основан на методике *Coco image (dataset)* [5]. Задача по распознаванию полезной культуры и сорной растительности упрощена: для полезной культуры собран датасет, а нежелательной растительностью определена любая другая культура, не распознанная как полезная. Тем самым исключена необходимость в подготовке дополнительных датасетов на многообразие сорной растительности, при сохранении высокого качества обработки.

Обученную нейронную сеть для роботизированного устройства установили на платформу искусственного интеллекта для автономных машин *Nvidia Jetson AGX Xavier*. Она ориентирована для проектов в сфере машинного зрения, робототехники, автопилотов для транспорта, где требуются высокоемкие вычисления поточного видео и графики [6].

Модули *Nvidia Jetson* – это компактные платы, содержащие на борту все компоненты полноценного компьютера: процессор, видеоадаптер, оперативную память, *USB*-контроллеры и т.д. Они предназначены для

встраивания в другие платы (*carrier board*), разработанные под конкретные задачи [7].

Обучение нейронной сети и тестирование обученной модели проходят в несколько этапов.

Сбор данных для нейронной сети по идентификации растений. На территории Агрофирмы «Поиск» (Московская область) в качестве тренировочных данных собраны более 3000 изображений капусты и около 1000 изображений других культур (*рис. 3*). Такой набор данных нужен для достижения требуемой точности распознавания искомым параметров растений. Сбор данных для капусты осуществляли непосредственно с роботизированного устройства, а также с помощью беспилотного летательного судна, с последующей нормализацией изображений под требования записывающего оборудования на роботизированном устройстве. В итоге удалось вдвое увеличить набор данных, при этом уменьшить зависимость от условий освещения и камеры и сохранить базовые параметры, такие как ракурс и культура.



Рис. 3. Изображения капусты для обучения алгоритма
Fig. 3. Cabbage patch images for training the algorithm

Разработка программного инструмента для подготовки данных. Программное обеспечение для автоматизации процесса подготовки данных позволяет упростить работу по выделению целевого сегмента исходного изображения. Программа написана на языке программирования *Python*, среда разработки – *Google Collaboratory* [8].

Программное обеспечение для разметки данных автоматизирует процессы:

- обработку собранных тренировочных данных для сегментационной нейронной сети;
- формирование обучающей маски изображения по очищенному от фона изображению;
- создание топологии директорий и обучающих файлов для тренировки сегментационной нейронной сети.



Разметка данных для обучения сегментационной нейронной сети глубокого обучения. Вручную, с использованием алгоритма выделения контура, подготовили тестовый набор данных. Это помогло упростить работу ручной обработки и повысить качество автоматического выделения контура (без ручной обработки этот метод не позволяет получить результат требуемого качества).

При обработке растений методом дифференцированного внесения агрохимических средств необходимо обеспечить распознавание полезной культуры и сорной растительности, определить площадь обработки, а именно координаты центра, радиуса и контура в системе отсчета роботизированного устройства. Эти параметры рассчитываются индивидуально для каждого растения.

Обозначенный контур дает возможность отделить интересующее растение от фона и других объектов, а также определить его положение и границы (рис. 4) [9]. При этом ни один из элементов не выходит за рамки обозначенного контура.

Контур растения помогает сократить площадь обработки и расход агрохимических средств вследствие их точечного внесения, а также повысить экономическую эффективность опрыскивания. Кроме того, внедрение такой технологии снижает уровень загрязнения сельскохозяйственных угодий и, соответственно, улучшает качество продукции.



Рис. 4. Определение целевой области растения
Fig. 4. Determining the plant target area

Поскольку растения различаются по форме, опрыскиваемый объем агрохимических средств при дифференцированном методе определяли как цилиндр с радиусом минимальной возможной окружности, включающей растение полностью, а высота цилиндра соответствует расположению крайней точки капусты (рис. 5) [10].

Работа системы дифференцированного внесения средств защиты растения основывается на радиусе и центре окружности. Радиус окружности выделенного контура рассчитывается для каждого растения индивидуально исходя из совокупности параметров системы «растение – устройство» [11]:

$$r = \left(h + \frac{h_0}{2} \right) \operatorname{tg} \left(\gamma - \frac{\beta}{2} \right) + r_0, \quad (1)$$

где r_0 – радиус растения, м;

h – высота форсунки относительно центральной

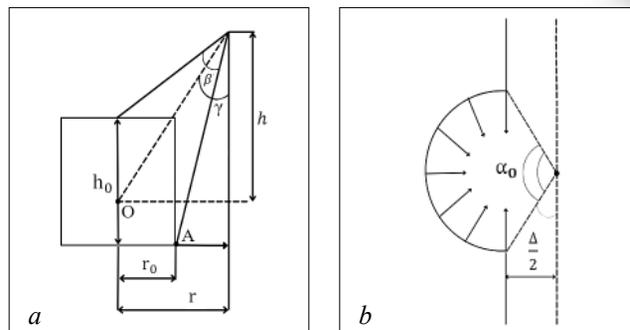


Рис. 5. Принцип работы системы внесения средств защиты растения: а – определение опрыскиваемого объема для обрабатываемой полевой культуры; б – взаимосвязь направления и траектории движения форсунки; О – центральная точка опрыскивания; А – крайняя точка границ обработки растения; β – угол распыла форсунки; γ – угол наклона форсунки; h – высота форсунки относительно центральной точки опрыскивания О; h_0 – высота растения, r_0 – радиус растения; r – радиус окружности

Fig. 5. The operation principle of the system for applying plant protection products: a – determining the volume to spray for the crop being treated; b – the relationship of the direction and trajectory of the nozzle movement; O – the central spraying spot; A – the extreme point of the plant treatment boundaries; β – the nozzle spray angle; γ – the nozzle tilt angle; h – the nozzle height against the central spraying spot O; h_0 – the height of the plant, r_0 – the radius of the plant; r – the radius of the circle

точки опрыскивания О, м;

h_0 – высота растения, м;

γ – угол наклона форсунки, рад;

β – угол распыла, рад.

Учитывая, что в начальный момент времени выполнения опрыскивания рабочий орган был уже отклонен, уравнение для угла поворота форсунки принимает вид:

$$\alpha = \frac{\alpha_0}{t_0} t + \frac{\pi - \alpha_0}{2}, \quad (2)$$

где α – угол поворота форсунки, рад;

α_0 – угол дуги опрыскивания одного растения одной форсункой, рад;

t_0 – время опрыскивания одного растения, с.

В уравнениях для координат принимаем во внимание значение угла поворота форсунки и его зависимость от траектории движения [12]:

$$x = r \sin \left(\frac{\alpha_0}{t_0} t + \frac{\pi - \alpha}{2} \right), \quad (3)$$

$$y = r \cos \left(\frac{\alpha_0}{t_0} t + \frac{\pi - \alpha}{2} \right) - vt, \quad (4)$$

где v – скорость движения роботизированного устройства, км/ч.

Для нахождения объекта и сегментации внутри найденных ограничивающих рамок был задан один класс – капуста. Однако обученную нейронную сеть можно применить к любой сельскохозяйственной культуре. Для этого достаточно одного пролета над

целевым полем с помощью беспилотного летательного судна для сбора данных.

Капуста выделялась масками попиксильно и автоматически обводился контур найденных масок для каждого растения. Это позволило получить точные маски белокачанной капусты (рис. 6).

В дальнейшем на основе собранных растений капусты без фона создавали синтетический датасет.

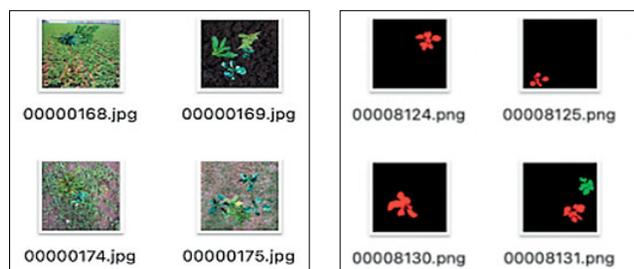


Рис. 6. Выделение границ белокачанной капусты
Fig. 6. Highlighting the boundaries of white cabbage

Обучение нейронной сети. Система компьютерного зрения устройства необходима, чтобы обеспечивать функциональные возможности и отвечать определенными техническими характеристиками. Алгоритм должен преобразовать полученные с камеры данные в режиме реального времени, сегментировать входное изображение и выдать результат в точной маске для последующей обработки, а также классифицировать тип объекта с точностью не менее 95% [13].

Скорость распознавания образов – не дольше 0,2 с на одно изображение [14]. Такой темп обработки обусловлен максимальной скоростью роботизированного устройства, достаточной для того, чтобы получить точное местоположение целевой области в любой момент времени.

Ввиду относительной простоты задачи, так как на данном этапе нейронная сеть обучается распознавать одну культуру (для других видов полезных культур предполагается использования данной методики, но уже с соответствующими новыми данными), и требований к быстродействию системы использованы архитектуры *Deeplabv3 plus* и *Mask-CNN*, оптимальные по скорости и точности. Нейросеть доработана под задачу классификации полезной культуры и сорной растительности и обучена на подготовленных ранее данных [15].

При обучении применяли практику случайного разделения датасета на 3 части – обучающую, валидационную и тестовую. Модель оценивается по качеству на валидационной выборке, а по завершении проходит финальное испытание на тестовых данных, которые были от нее закрыты в процессе обучения [16].

Количество данных для обучения составило:

16000 элементов – обучающий набор (искусственный);

4000 элементов – валидационный набор, используемый для оценки качества во время обучения (искусственный);

500 элементов – тестовые: 250 – одно растение в кадре, 250 – несколько растений в кадре (реальный набор) (рис. 7).

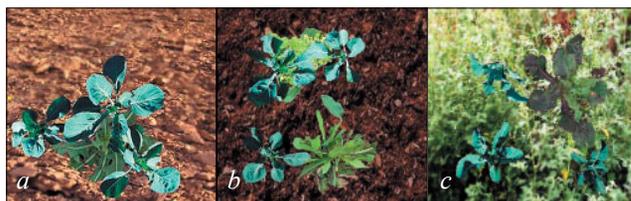


Рис. 7. Моделирование данных для обучения модели с целью применения в разных условиях: а – фон с малым числом сорной растительности; б – фон со средним числом сорной растительности; с – фон с большим количеством сорной растительности

Fig. 7. Data modelling to train the model for application in different conditions: a – a background sample with a small number of weeds; b – a background sample with an average number of weeds; c – a background sample with a large amount of weeds

Тестовые данные с разным количеством сорной растительности на фоне и различным типом почвы используются для проверки работы алгоритма при любых условиях. Для каждого уникального случая применения роботизированного устройства обязательно обучение алгоритма в привязке к обрабатываемой культуре. Обучение алгоритма при возможности следует проводить на фоне, близком к реальному, но при отсутствии такой возможности – на различных фонах.

Полученные данные подтверждают использование разработанного алгоритма на многих сельскохозяйственных культурах, выращиваемых на неоднородных почвенно-растительных покровах.

Обучение проводили на 5 эпохах (наилучшие результаты). Размер тренировочного пакета данных – 32 изображения.

Результаты и обсуждение. Как показало тестирование модели для определения точности распознавания растений среди сорной растительности, модель

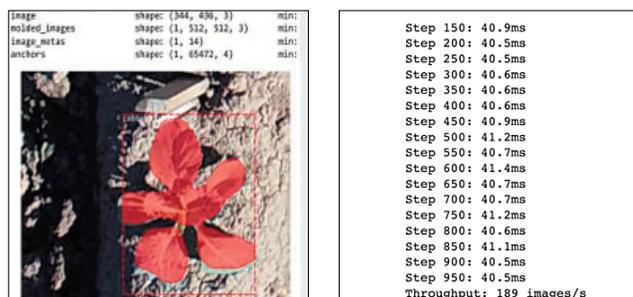


Рис. 8. Результат работы алгоритма на реальных данных: а – реальные данные; б – скорость выполнения алгоритма
Fig. 8. The algorithm output based on the actual data: a – actual data; b – algorithm execution speed

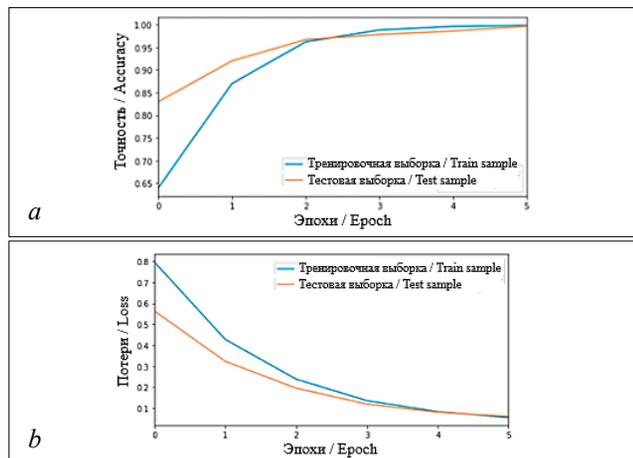


Рис. 9. Динамика точности (а) и потерь (b) на тренировочных и тестовых данных в процессе обучения
 Fig. 9. Dynamics of accuracy (a) and loss (b) on training and test data during training

обучилась извлекать координаты ограничительной рамки и местоположение объекта (капусты) по пикселям с требуемой точностью – как для синтетических, так и для реальных данных.

Далее измеряли скорость распознавания, где наилучшим образом показала себя модель на основе *Deeplabv3 plus* (160 мс на изображение против 720 мс для *Mask R-CNN*). Выбранную модель подготовили к инференсу и получили результаты скорости распознавания на сервере *GoogleCollaboratory* с GPU (рис. 8).

Графики точности и потерь при обучении выбранной архитектуры на тренировочных и тестовых дан-

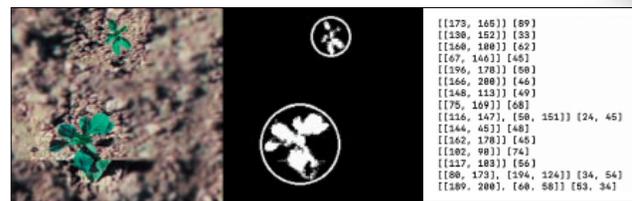


Рис. 10. Координаты центра окружности и радиуса, необходимые для обработки растения
 Fig. 10. The circle center and radius coordinates required for processing the plant

ных наглядно показывают, что оптимальное количество эпох для обучения набора данных – 5, далее процесс обучения выходит на плато без улучшений алгоритма, что указывает на его переобучение (рис. 9).

Количество распознанных растений составило 98%, точность выделения контура – 94%, а 6% части растения не выделяется правильно на указанных данных. Однако это не влияет существенно на результат обучения, поскольку распознанная часть растения использовалась для описания окружности, соответствующей площади обработки культуры (рис. 10).

Выводы. В результате оценки модели на тестовых данных получили следующие значения: количество найденных растений – 98%, точность выделения контура – 94%.

Обученная нейронная сеть может быть применима к любым выращиваемым культурам, с учетом неоднородности их расположения на поле, независимо от типов почвы и количества сорной растительности.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Мирзаев М.А. Проектирование автономного полевого робота для дифференцированного внесения агрохимических средств // *Электротехнологии и электрооборудование в АПК*. 2021. Т. 68. N4(45). С. 131-136.
2. Zhao K., et al. Building extraction from satellite images using mask R-CNN with building boundary regularization. *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2018. 247-251.
3. Weber M., et al. Deeplab2: A tensorflow library for deep labeling. arXiv preprint arXiv:2106. 09748v1. 2021.
4. Wang H., et al. Max-deeplab: End-to-end panoptic segmentation with mask transformers. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2021. 5463-5474.
5. Caesar H., Uijlings J., Ferrari V. Coco-stuff: Thing and stuff classes in context. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018. 1209-1218.
6. Jeon J., et al. Run your visual-inertial odometry on NVIDIA Jetson: Benchmark tests on a micro aerial vehicle. *IEEE Robotics and Automation Letters*. 2021. Vol. 6. N3. 5332-5339.
7. Hossain S., Lee D. Deep learning-based real-time multiple-object detection and tracking from aerial imagery via a flying robot with GPU-based embedded devices. *Sensors*. 2019. Vol. 19. N15. 3371.
8. Carneiro T., et al. Performance analysis of google colab as a tool for accelerating deep learning applications. *IEEE Access*. 2018. Vol. 6. 61677-61685.
9. Meyer G.E., Neto J.C. Verification of color vegetation indices for automated crop imaging applications. *Computers and electronics in agriculture*. 2008. Vol. 63. N2. 282-293.
10. Демин Е.Е. и др. Аналитические исследования технических параметров самодвижущихся опрыскивателей // *Аграрный научный журнал*. 2021. N12. С. 112-114.
11. Балабанов В.И. и др. Технологии, машины и оборудование для координатного (точного) земледелия. М.: Росинформагротех. 2016. 240 с.
12. Лысов А.К., Воробьев Н.И. Вычисление с помощью математической модели траекторий движения распыляемых аэрозольных капель // *АгроЭкоИнженерия*. 2021. N2(107). С. 96-106.
13. Бредихин А.И. Алгоритмы обучения сверточных нейронных сетей // *Вестник Югорского государственного университета*. 2019. N1(52). С. 41-54.
14. Henaff O. Data-efficient image recognition with contrastive

- predictive coding. *International Conference on Machine Learning*. PMLR. 2020. 4182-4192.
15. Bardou D., Zhang K., Ahmad S. M. Classification of breast cancer based on histology images using convolutional neural networks. *IEEE Access*. 2018. Vol. 6. 24680-24693.
16. Polyzotis N., Zinkevich M., Roy S., Breck E., Whang S. Data Validation for Machine Learning. *Proceedings of Machine Learning and Systems*. 2019.

REFERENCES

- Mirzaev M.A. Proektirovanie avtonomnogo polevogo robota dlya differentsirovannogo vneseniya agrokhimicheskikh sredstv [Design of an autonomous field robot for differentiated application of agrochemical agents]. *Elektrotekhnologii i elektrooborudovanie v APK*. 2021. Vol. 68. N4(45). 131-136 (In Russian).
- Zhao K., et al. Building extraction from satellite images using mask R-CNN with building boundary regularization. *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2018. 247-251 (In English).
- Weber M., et al. Deeplab2: A tensorflow library for deep labeling. arXiv preprint arXiv:2106.09748v1. 2021 (In English).
- Wang H., et al. Max-deeplab: End-to-end panoptic segmentation with mask transformers. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2021. 5463-5474 (In English).
- Caesar H., Uijlings J., Ferrari V. Coco-stuff: Thing and stuff classes in context. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018. 1209-1218 (In English).
- Jeon J., et al. Run your visual-inertial odometry on NVIDIA Jetson: Benchmark tests on a micro aerial vehicle. *IEEE Robotics and Automation Letters*. 2021. Vol. 6. N3. 5332-5339 (In English).
- Hossain S., Lee D. Deep learning-based real-time multiple-object detection and tracking from aerial imagery via a flying robot with GPU-based embedded devices. *Sensors*. 2019. Vol. 19. N15. 3371 (In English).
- Carneiro T. et al. Performance analysis of google colab as a tool for accelerating deep learning applications. *IEEE Access*. 2018. Vol. 6. 61677-61685 (In English).
- Meyer G.E., Neto J.C. Verification of color vegetation indices for automated crop imaging applications. *Computers and electronics in agriculture*. 2008. Vol. 63. N2. 282-293 (In English).
- Demin E.E., et al. Analiticheskie issledovaniya tekhnicheskikh parametrov samodvizhushchikhsya opryskivatelye [Analytical studies of technical parameters of self-propelled sprayers]. *Agrarnyy nauchnyy zhurnal*. 2021. N12. 112-114 (In Russian).
- Balabanov V.I., et al. Tekhnologii, mashiny i oborudovanie dlya koordinatnogo (tochnogo) zemledeliya [Technologies, machines and equipment for coordinate (precision) farming]. Moscow: Rosinformagrotekh. 2016. 240 (In Russian).
- Lysov A.K., Vorob'ev N.I. Vychislenie s pomoshchyu matematicheskoy modeli traektorii dvizheniya raspylyaemykh aerosol'nykh kapel' [Calculation of droplets trajectories of a sprayed aerosol with the use of mathematical model]. *Agro-EkoInzheneriya*. 2021. N2(107). 96-106 (In Russian).
- Bredikhin A.I. Algoritmy obucheniya svertochnykh neyronnykh setey [Training algorithms for convolutional neural networks]. *Vestnik Yugorskogo gosudarstvennogo universiteta*. 2019. N1(52). 41-54 (In Russian).
- Henaff O. Data-efficient image recognition with contrastive predictive coding. *International Conference on Machine Learning*. PMLR. 2020. 4182-4192 (In English).
- Bardou D., Zhang K., Ahmad S. M. Classification of breast cancer based on histology images using convolutional neural networks. *IEEE Access*. 2018. Vol. 6. 24680-24693 (In English).
- Polyzotis N., Zinkevich M., Roy S., Breck E., Whang S. Data Validation for Machine Learning. *Proceedings of Machine Learning and Systems*. 2019 (In English).

Конфликт интересов

Автор заявляет об отсутствии конфликта интересов.
Автор прочитал и одобрил окончательный вариант.

Conflict of interest

The author declares no conflict of interest.
The author read and approved the final manuscript.

Статья поступила в редакцию
Статья принята к публикации

The paper was submitted to the Editorial Office on
The paper was accepted for publication on

07.06.2022
06.09.2022