

Научная статья

УДК 631.171

doi:10.35694/YARCX.2023.63.3.013

ИДЕНТИФИКАЦИЯ ОСНОВНЫХ ТИПОВ КОРМОВЫХ КУЛЬТУР И СОРНЯКОВ НА ИЗОБРАЖЕНИЯХ С ПОЛЕЙ МЕТОДАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

В. В. Хрящёв¹, А. С. Ключников², Н. В. Котов³, Р. В. Ларинов⁴

^{1, 3, 4}Ярославский государственный университет им. П. Г. Демидова, Ярославль, Россия

²Ярославский государственный технический университет, Ярославль, Россия

Автор, ответственный за переписку: Артём Сергеевич Ключников

artik8487@mail.ru, ORCID 0000-0002-7947-2099

Реферат. Использование аэрофотосъёмки существенно расширяет инструментарий агрономов. Целесообразно для автоматизации обработки больших объёмов данных, получаемых с беспилотного летательного аппарата, применить технологии искусственного интеллекта. Практическое применение технологий искусственного интеллекта требует предварительного обучения нейронных сетей. Процесс обучения предполагает обработку большого количества примеров изображений, на которых представлены объекты интересующих классов. Создание таких «примеров» возможно путём анализа и обработки информации на экспериментально собранных изображениях, т.е. разметки. В работе рассмотрены сети ResNet-34, MobileNetV2. Предложен новый алгоритм подготовки данных для использования методов машинного обучения в задаче идентификации основных типов кормовых культур и сорняков на изображениях. Алгоритм исследован на изображениях, полученных на высоте 5 метров с камеры беспилотного летательного аппарата. Разрешение изображений 1600x1300 пикселей с тремя каналами в следующем порядке: синий, красный, зелёный. Суммарно сформирован набор из 3000 патчей, распределённый на подвыборки: тренировочная, тестовая, валидационная. Сравнение результатов тестовой прогонки изображений через нейросети, прошедшие обучение, показали высокую сходимость с результатами валидации, что говорит о перспективности применения разработанного алгоритма. Экспериментально показано, что точность распознавания целевых объектов предобученных нейросетей на изображении возрастает десятикратно.

Ключевые слова: машинное зрение, обучение нейросетей, аэрофотосъёмка, искусственный интеллект в сельском хозяйстве, разметка изображения, мониторинг полей

IDENTIFICATION OF MAIN TYPES OF FEED CROPS AND WEEDS ON IMAGES FROM THE FIELDS BY ARTIFICIAL INTELLIGENCE TECHNIQUES

Vladimir V. Khryashchev¹, Artem S. Klyuchnikov², Nikita V. Kotov³, Roman V. Larionov⁴

^{1, 3, 4}P. G. Demidov Yaroslavl State University, Yaroslavl, Russia

²Yaroslavl State Technical University, Yaroslavl, Russia

Author responsible for corespondence: Artem S. Klyuchnikov

artik8487@mail.ru, ORCID 0000-0002-7947-2099

Abstract. The use of aerial photography significantly expands the tools of agronomists. It is advisable to use artificial intelligence technologies to automate the processing of large amounts of data received from an unmanned aerial vehicle. The practical application of artificial intelligence technologies requires preparatory training of neural networks. The learning process involves processing a large number of example images that represent objects of interest classes. The creation of such “examples” is possible by analyzing and processing information on experimentally collected images, i.e. markings. The work deals with ResNet-34 and MobileNetV2 networks. A new algorithm for preparing data for using machine learning methods in the task of identifying the main types of feed crops and weeds in images was proposed. The algorithm was investigated in images obtained at a height of 5 meters from an unmanned aerial vehicle camera. The image resolution

1600x1300 pixels with three channels in the following order: blue, red, green. In total, a set of 3000 patches was formed, distributed into subsamples: training, test, validation. Comparison of the results of the test run of images through neural networks that have been trained showed high convergence with the validation results, which indicates the promise of using the developed algorithm. Experimentally, it has been shown that recognition accuracy of target objects of pre-trained neural networks in an image increases tenfold.

Keywords: machine vision, neural network training, aerial photography, artificial intelligence in agriculture, image marking, field monitoring

Финансирование: исследование выполнено за счет средств Программы развития ЯрГУ до 2030 года, проект № GM-2023-СП-03/2021 «Разработка методик и алгоритмов прогнозирования характеристик урожайности кормовых культур с использованием анализа данных, методов компьютерного зрения и искусственного интеллекта».

Введение. Традиционные способы мониторинга и контроля процесса роста и созревания сельскохозяйственных растений характеризуются значительными затратами времени и отвлечением человеческих ресурсов. Они требуют периодического выезда агрономов непосредственно на поле для осмотра и оценки состояния посевов. Кроме того, проведение обследования бывает затруднено, так как в середине вегетационного периода пройти вглубь поля не всегда представляется возможным.

При повреждении вредителями или появлении заболеваний на участках, удалённых от края поля, возникает риск выявления проблемы тогда, когда время для её устранения уже упущено [1]. Традиционное обследование полей позволяет получить лишь усреднённую картину поля. Оно не даёт возможности проводить точечные обследования поля там, где они действительно необходимы, не позволяет уделить внимание отдельным зонам, участкам с даже незначительными отличиями, пока они не вышли в ту проблему, которая видна невооружённым глазом.

На современном этапе развития для реализации концепции ресурсосберегающего и точного сельского хозяйства, не разрушающего среду обитания человека и сохраняющего безопасность получаемой сельскохозяйственной продукции, требуется переход от глазомерной субъективной оценки поля к анализу, основанному на машинном зрении и аэромобильных технологиях.

Использование аэрофотосъёмки существенно расширяет инструментарий агрономов, однако оно требует ряда специальных решений для автоматизации обработки получаемой информации. Одной из существенных особенностей подобной технологии является использование вертикально вниз направленной камеры. С одной стороны, она позволяет точно определить проективное покрытие всех видов, с другой, существенно затрудняет определение высоты растений.

Особое внимание следует обратить на то, что в агрономии превалирует негативное восприятие

сорной флоры. Типичная её агрономическая классификация основана на способах сорных растений к возобновлению на полях и методах их уничтожения с упором на неселективные. Традиционно массовое применение химических средств защиты растений является одним из обязательных этапов сельскохозяйственного производства. Однако современная и перспективная техника позволяет снизить объёмы расхода средств защиты растений и вести персонифицированную работу с сорняками, учитывая их состояние и индивидуальную чувствительность.

Для больших посевых площадей характерна некоторая пестрота посевов и, как следствие, неизбежные различия в выполненности культурных растений и видовом составе сорняков. Такие участки требуют фокусного внимания, а для их отслеживания необходимо обрабатывать большие объёмы информации. В таком случае целесообразно применить технологии искусственного интеллекта (ИИ). Они сыграли широкое распространение в различных областях сельского хозяйства, таких как: обнаружение болезней растений, классификация и идентификация сорняков, определение и подсчёт плодов, управление водными ресурсами и почвой, прогнозирование погоды (климата), определение поведения животных [2].

Следует отметить, что практическое применение технологий ИИ требует предварительного обучения нейронных сетей. Для их обучения необходимо большое количество примеров изображений, на которых представлены объекты интересующих классов, чтобы научиться находить их самостоятельно. Создание таких «примеров» возможно путём анализа и обработки информации на экспериментально собранных изображениях, т.е. разметки.

Цель исследования – разработать алгоритм подготовки данных для использования методов машинного обучения в задаче идентификации основных типов кормовых культур и сорняков на изображениях с полей Ярославского НИИЖК – филиала ФНЦ «ВИК им. В. Р. Вильямса».

Материалы и методы. Для обучения нейросетевых алгоритмов необходимо большое количество данных, в особенности, если в основе лежат алгоритмы глубокого обучения. Нами использованы сети ResNet-34, MobilenetV2 с 21 млн и 3,4 млн параметров соответственно. Но, в соответствии с принципом трансферного обучения сетей, данные архитектуры уже обучены на больших объемах изображений. Таким образом, для реального обучения сетей среди собственных классов обучаются только последние несколько слоёв сети классификатора. Количество изображений на этапе проведения обучения в рамках самой большой по числу параметров сети должно быть не менее 3000 штук при разрешении 256x256 пикселей. При этом предполагается, что база будет увеличиваться за счёт сбора новых актуальных данных, а соответствующая нейросетевая модель – дообучаться.

В исследовании использованы изображения, полученные на высоте 5 метров с камеры беспилотного летательного аппарата (БПЛА) с разрешением 1600x1300 пикселей с тремя каналами в следующем порядке: синий, красный, зелёный. В результате, для каждого изображения соответствуют несколько типов классификаций. Суммарно сформирован набор из 3000 патчей, распределённый на подвыборки: тренировочная, тестовая, валидационная.

В рамках исследования выбраны следующие типы целевых классификаций для кормовых культур – культура растения, стадия развития, плотность культурных растений (табл. 1), а также типы целевых классификаций для сорняков – вид сорной растительности, стадия развития сорной растительности, плотность сорной растительности (табл. 2).

Задача исследования заключается в оценке адекватности работы обученных по разработанному алгоритму нейросетей путём сравнения ре-

зультатов тестового прогона подвыборки «тест» и результатов оценки её экспертами, подвыборка «валидационная».

Результаты и обсуждение. Обучение нейросетей требует проведения разметки изображений. Как показывает опыт, для минимизации ошибок, ликвидации спорных ситуаций разметку необходимо проводить в два последовательных этапа:

- первичная разметка;
- валидационная разметка.

Первый этап является основным и заключается в разделении видов культурной растительности и сорняков на изображениях, полученных с камеры БПЛА. Суть процесса заключена в создании пары изображений: исходный снимок объекта и метка целевого класса, как показано на рисунке 1.

Вид разметки может меняться в зависимости от решаемой в ходе разработки алгоритма задачи. Наиболее распространены два вида. Детектирование, которое, по своей сути, представляет задачу одновременной классификации нескольких объектов на изображении, при этом для объектов определяется их расположение в кадре путём внедрения ограничивающих рамок. Сегментация, которая позволяет делить изображение на непересекающиеся области, повторяющие границы объектов, каждая из которых характеризует объект определенного класса [3].

Для успешного проведения разметки изображений необходимо разработать методику. Она должна включать следующие разделы: сортировка изображений; группировка изображений по классам; экспертная разметка изображений с помощью специализированного программного обеспечения; анализ результатов разметки.

Валидация созданной разметки – процесс проверки, корректировки и утверждения имеющейся разметки [4]. Её необходимо провести по следующим направлениям: проверка удалённых кадров;

Таблица 1 – Классы целевых типов классификации кормовых культур

Целевой тип	Классы
Культура растений	Вико-овсяная смесь; другое; кукуруза; многолетние травы; чистый пар; яровая тритикале; ячмень
Стадия развития	Вегетация; всходы; вымётывание; колошение; кущение; нет; отрастание; фаза 5–21 листьев; цветение
Плотность культурных растений	0; 50; 100

Таблица 2 – Типы целевых классификаций для сорняков

Целевой тип	Классы
Вид сорной растительности	Корневые; яровые; прочие; нет
Стадия развития сорной растительности	Нет; вегетация; всходы; цветение
Плотность сорной растительности	0; 50; 100

Идентификация основных типов кормовых культур и сорняков на изображениях с полей методами искусственного интеллекта

проверка отобранных в результате сортировки кадров; проверка разбиения собранной базы изображений на группы; проверка и корректировка разметки изображений.

Правильность разметки определяется по следующим критериям: проведена классификация объекта, т.е. файл разметки расширением «.json» содержит метку класса соответствующего целевого типа классификации; при воспроизведении изображения через программное обеспечение результат успешно отображается на экране; классы объекта целевого типа классификации, созданные на предыдущем этапе разметки, определены правильно.

Следует отметить, что для работы с нейронной сетью необходимо привести значения яркости пикселей нормализованного изображения к диапазону 0, 1. При этом исходно изображения в наборе имеют значения яркости пикселей, распределённых в диапазоне 0, 255. Поэтому необходимо провести предобработку полученной базы изображений. Существуют следующие методы – стандартизация, масштабирование и усреднённая нормализация признаков [5].

Стандартизация – пиксели сначала нормализуются по среднему значению, а затем по стандартному отклонению по каждому из пикселей обучающей выборки. Таким образом, необработанные данные нормализованы как по отношению к среднему, так и к дисперсии значений пикселей изображения обучающей выборки. Математическим языком метод представлен формулой (1).

$$X^I = \frac{X - \mu}{\sigma}, \quad (1)$$

где X^T – нормированные данные; X – ненормированные данные; μ – средний вектор по всей функции; σ – вектор стандартного отклонения по всем особенностям. Данный способ приведения значений яркости пикселей используется, если распределение яркости пикселей неравномерное (т.е. если существует смещение плотности распределения гистограммы пикселей в сторону максимальных или минимальных значений).

Масштабирование признаков – значение каждого пикселя делится на максимальное значение яркости пикселей изображения. Таким образом, значение яркости пикселей стандартизованного изображения тренировочного набора можно представить по формуле (2):

$$X' = \frac{X}{255}, \quad (2)$$

где X – значения яркости пикселей до преобразования; X' – значения яркости пикселей после преобразования. Так как изображения в выборке являются 8-битными, т.е. диапазон значений яркости 0, 255, соответственно, значение знаменателя в формуле (2) равно 255.

Усреднённая нормализация – это взятие среднего значения по каждому из пикселей (по размеру изображения) обучающих выборок, которое вычитается из каждого значения пикселей изображения и делится на среднее значение пикселей. Таким образом, значение яркости пикселей изображений тренировочного набора можно представить выражением вида:

$$X' = \frac{X - \mu}{\mu}, \quad (3)$$

где X' – нормализованные значения пикселей;
 X – исходные значения пикселей; μ – среднее значение по всем пикселям X . Данный способ приведения значений яркости пикселей применяется к изображениям с равномерным распределением яркости пикселей по гистограмме изображения.

Для того чтобы снизить огромные трудозатраты экспертов в процессе разметки фрагментов изображений и цельных изображений, разработана методика полуавтоматической разметки областей интереса для последующего обучения и/или тестирования нейросетевых моделей. Данная методика предполагает формирование основы для разметки алгоритмом, обученным на предыдущих этапах исследования, с доработкой полученной разметки специалистом по работе с изображениями.



Рисунок 2 – Структурная схема методики полуавтоматической разметки областей интереса на изображениях с БПЛА

Таблица 3 – Распределение по подвыборкам для фазы культур

Класс	Тренировочный	Тестовый	Валидационный
Вегетация	465	52	65
Всходы	48	9	3
Вымётывание	112	16	13
Колошение	298	46	36
Кущение	143	20	11
Нет	916	83	119
Отрастание	330	31	43
Фаза 5–21 листьев	48	3	2
Цветение	70	10	8

Таблица 4 – Распределение по подвыборкам для типа культур

Класс	Тренировочный	Тестовый	Валидационный
Вико-овсяная смесь	259	31	27
Другое	62	8	10
Кукуруза	102	13	12
Многолетние травы	684	73	2
Чистый пар	846	75	106
Яровая тритикале	249	34	25
Ячмень	228	36	28

Таблица 5 – Распределение по подвыборкам для плотности культур

Класс	Тренировочный	Тестовый	Валидационный
0	942	84	119
50	854	102	104
100	634	84	77

Таблица 6 – Распределение по подвыборкам для вида сорной растительности

Класс	Тренировочный	Тестовый	Валидационный
Корневые	1098	117	139
Яровые	281	38	33
Прочие	83	6	9
Нет	968	109	119

Таблица 7 – Распределение по подвыборкам для стадии развития сорной растительности

Класс	Тренировочный	Тестовый	Валидационный
Нет	974	109	120
Вегетация	975	106	120
Всходы	251	22	29
Цветение	230	33	31

ями (разметчик), который, в свою очередь, консультируется с экспертами.

Разработанная схема включает шесть этапов (рис. 2).

1. Разметка фрагментов изображений с БПЛА, обученных на предыдущем этапе алгоритмами ResNet-34 [6], MobilenetV2 [7]. Сохраняются фрагменты с целевыми классами, по 5 кадров, чтобы сохранялась контекстная информация для дальнейших этапов разметки. Отбор предсказанных алгоритмом кадров каждого класса, для которых оценка достоверности принадлежности объекта к классу превышает 0,3; присвоение класса classification и сохранение вместе с отметками эксперта в специальном текстовом формате сериализации – json, с которым можно далее работать в программе разметки labelme.

2. Разметчик просматривает полученные кадры с разметкой в хронологическом порядке и удаляет ложноположительные предсказания алгоритма, ошибочность которых для него очевидна и объединяет в один пакет. Если объект на рассматриваемой последовательности кадров соответствует отметке эксперта, полученной с тестового стенда, любой рамке из данного трека присваивается соответствующий класс, а соответствующей отметке эксперта – идентификационный номер кадра рассматриваемого объекта.

3. Проверяется согласованность данных – все объекты одной последовательности приводятся к одному классу. Выбираются все последовательности соответствующего класса, и последовательности кадров сохраняются в отдельные директории.

4. Эксперт рассматривает полученные на предыдущем этапе директории и выносит экспертную оценку, соответствует ли 91 объект на последовательности соответствующему классу или нет, а также отмечают неправильную классификацию.

5. Разметчик, руководствуясь результатами экспертизы, полученной на предыдущем этапе, присваивает последовательностям соответствующие классы, если это соответствует экспертной разметке, а остальные последовательности удаляет.

6. Снова проверяется согласованность данных. Руководствуясь данной методикой, выпол-

нена разметка фрагментов изображений с БПЛА с целью формирования тестового набора изображений. Стоит отметить, что данную методику можно применять итеративно для разметки большого количества данных. На каждой итерации стоит размечать часть данных и дообучать алгоритм на новых данных, тогда следующая итерация будет требовать меньше трудозатрат, т.к. качество автоматической разметки будет возрастать. Как показывает практика, трудозатраты при создании размеченных баз изображений уменьшаются на 30–40%.

Результаты применения разработанного алгоритма подготовки данных для использования методов машинного обучения в задаче идентификации основных типов кормовых культур и сорняков на изображениях с полей Ярославского НИИЖК – филиала ФНЦ «ВИК им. В. Р. Вильямса» представлены в таблицах 3–7.

Сравнение результатов тестовой прогонки изображений с БПЛА через нейросети, прошедшие обучение по разработанной методике, с результатами валидации показали высокую сходимость, что свидетельствует о перспективности применения разработанного алгоритма. Подвыборка «тренировочный» показывает результат работы нейросети до проведения обучения. Как видно из значений в таблицах, точность распознавания целевых объектов возросла на порядок.

Выводы. С целью снижения высоких трудозатрат в процессе разметки фрагментов изображений и цельных изображений целесообразно применять алгоритм полуавтоматической разметки областей интереса для последующего обучения и/или тестирования нейросетевых моделей. Данная методика предполагает формирование основы для разметки предобученным алгоритмом, с доработкой полученной разметки специалистом по работе с изображениями (разметчиком), который, в свою очередь, консультируется с экспертами. Точность распознавания целевых объектов на изображении возрастает десятикратно. Предложенную методику можно применять для разметки других видов данных практически без изменения, а также для иных типов распознавания изображений с помощью нейронных сетей – детекция, сегментация.

Список источников

1. Ивченко В. К., Демьяненко Т. Н., Ильченко И. О. [и др.] Использование наземных спектрофотометрических измерений для выявления влияния приемов основной обработки почвы на процесс нарастания надземной фитомассы яровой пшеницы в зернопаропропашном севообороте // Вестник КрасГАУ. 2020. № 1 (154). С. 3–11. DOI 10.36718/1819-4036-2020-1-3-11.
2. Айтпаева А. А. Цифровизация сельского хозяйства в контексте повышения конкурентоспособности отечественного АПК // Вестник Астраханского государственного технического университета. Серия: Экономика. 2019. № 3. С. 56–63. DOI 10.24143/2073-5537-2019-3-56-63.

3. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook. Cham: Springer, 2018. 512 p.
4. Szegedy C., Liu W., Jia Y. Going deeper with convolutions // In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015. P. 1–9. DOI 10.1109/CVPR.2015.7298594.
5. Каличкин В. К., Корякин Р. А., Лужных Т. А. [и др.] Выбор и размещение сельскохозяйственной культуры с использованием искусственного интеллекта // Достижения науки и техники АПК. 2019. Т. 33, № 10. С. 67–70. DOI 10.24411/0235-2451-2019-11015.
6. Кучкаров З. А. Методические основы концептуального анализа сложных систем и предметных областей // Интеграл. 2014. № 4. С. 88–92. ISSN 2074-0077.
7. Лысенко С. А. Прогнозирование урожайности сельскохозяйственных культур на основе спутникового мониторинга динамики углерода в наземных экосистемах // Исследование Земли из космоса. 2019. № 4. С. 48–59. DOI 10.31857/S0205-96142019448-59.

References

1. Ivchenko V. K., Dem'yanenko T. N., Il'chenko I. O. [i dr.] Ispol'zovanie nazemnyh spektrofotometricheskikh izmerenij dlya vyyavleniya vliyaniya priemov osnovnoj obrabotki pochvy na process narastaniya nadzemnoj fitomassy yarovoj pshenicy v zernoparopropashnom sevooborote // Vestnik KrasGAU. 2020. № 1 (154). S. 3–11. DOI 10.36718/1819-4036-2020-1-3-11.
2. Ajtpaeva A. A. Cifrovizaciya sel'skogo hozyajstva v kontekste povysheniya konkurentospособnosti otechestvennogo APK // Vestnik Astrahanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Ekonomika. 2019. № 3. S. 56–63. DOI 10.24143/2073-5537-2019-3-56-63.
3. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook. Cham: Springer, 2018. 512 p.
4. Szegedy C., Liu W., Jia Y. Going deeper with convolutions // In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015. P. 1–9. DOI 10.1109/CVPR.2015.7298594.
5. Kalichkin V. K., Koryakin R. A., Luzhnykh T. A. [i dr.] Vybor i razmeshchenie sel'skohozyajstvennoj kul'tury s ispol'zovaniem iskusstvennogo intellekta // Dostizheniya nauki i tekhniki APK. 2019. Т. 33, № 10. S. 67–70. DOI 10.24411/0235-2451-2019-11015.
6. Kuchkarov Z. A. Metodicheskie osnovy konceptual'nogo analiza slozhnyh sistem i predmetnyh oblastej // Integral. 2014. № 4. S. 88–92. ISSN 2074-0077.
7. Lysenko S. A. Prognozirovaniye urozhajnosti sel'skohozyajstvennyh kul'tur na osnove sputnikovogo monitoringa dinamiki ugleroda v nazemnyh ekosistemah // Issledovanie Zemli iz kosmosa. 2019. № 4. S. 48–59. DOI 10.31857/S0205-96142019448-59.

Сведения об авторах

Владимир Вячеславович Хрящёв – кандидат технических наук, доцент, доцент кафедры цифровых технологий и машинного обучения, Федеральное государственное бюджетное образовательное учреждение высшего образования «Ярославский государственный университет имени П. Г. Демидова», spin-код: 9120-0410.

Артём Сергеевич Ключников – кандидат технических наук, доцент кафедры компьютерно-интегрированной технологии машиностроения, Федеральное государственное бюджетное образовательное учреждение высшего образования «Ярославский государственный технический университет», spin-код: 5546-2339.

Никита Валерьевич Котов – аспирант кафедры цифровых технологий и машинного обучения, Федеральное государственное бюджетное образовательное учреждение высшего образования «Ярославский государственный университет имени П. Г. Демидова», spin-код: 3620-9968

Роман Васильевич Ларинов – аспирант кафедры цифровых технологий и машинного обучения, Федеральное государственное бюджетное образовательное учреждение высшего образования «Ярославский государственный университет имени П. Г. Демидова», spin-код: 8165-8027.

Information about the authors

Vladimir V. Khryashchev – Candidate of Technical Sciences, Docent, Associate Professor of the Department of Digital Technologies and Machine Learning, P. G. Demidov Yaroslavl State University, spin-code: 9120-0410.

Artem S. Klyuchnikov – Candidate of Technical Sciences, Associate Professor of the Department of Computer-Integrated Engineering Technology, Federal State Budgetary Educational Institution of Higher Education "Yaroslavl State Technical University", spin-code: 5546-2339.

Nikita V. Kotov – postgraduate student of the Department of Digital Technologies and Machine Learning, P. G. Demidov Yaroslavl State University, spin-code: 3620-9968

Roman V. Larionov – postgraduate student of the Department of Digital Technologies and Machine Learning, P. G. Demidov Yaroslavl State University, spin-code: 8165-8027.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

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