

Методика сегментации изображений беспилотных летательных аппаратов с помощью нейронных сетей

М. Ю. Катаев¹, Е. Ю. Карташов¹, В. В. Рябухин¹, Е. В. Макаров¹, О. А. Пасько²

¹ *Томский государственный университет систем управления и радиоэлектроники
Томск, 634050, Россия
E-mail: kmy@asu.tusur.ru*

² *Национальный открытый институт г. Санкт-Петербург
Санкт-Петербург, 197183, Россия
E-mail: o.pasko@noironline.ru*

Беспилотные летательные аппараты (БПЛА) получили широкое распространение в различных отраслях народного хозяйства, в том числе в сельском хозяйстве. Их преимущество заключается в высокой скорости и значительной площади сельскохозяйственных (с.-х.) полей, захватываемых цифровым изображением (ортофотопланы). Это снижает долю рутинной работы и сокращает время контроля за состоянием с.-х. культур соответствующими специалистами. Значительный технологический прогресс в области средств разработки конструкции БПЛА, методик измерений, программного обеспечения обработки результатов измерений (изображений) позволил сформировать такое направление, как «точное земледелие». Обработка полученных изображений типично выполняется или методами компьютерного зрения, или с помощью нейронных сетей, а в последнее время — с помощью свёрточных нейронных сетей (СНС). Несмотря на то, что СНС стали мощным инструментом решения задач обработки изображений БПЛА, есть задачи, которые ещё решаются недостаточно точно с помощью как методов компьютерного зрения, так и СНС. Приведена методика сегментации СНС-изображений с.-х. полей, полученных с помощью БПЛА. Рассмотрены особенности решения задачи с учётом малого количества материалов для обучения СНС, а также приведены полученные результаты.

Ключевые слова: беспилотный летательный аппарат, БПЛА, изображение, свёрточная нейронная сеть, сегментация

Одобрена к печати: 31.01.2023
DOI: 10.21046/2070-7401-2023-20-1-55-66

Введение

Сельское хозяйство — важный элемент народного хозяйства России и актуальное направление внедрения инноваций. Оно обращено на производство сырья для пищевой и перерабатывающей промышленности, достижение продовольственной безопасности и получение сырья для других отраслей (химическая, лёгкая промышленность) (Прогноз..., 2017). Динамику и стабильность производства ограничивают: сокращение населения, занятого в работе аграрного сектора; поддержка территорий сельхозугодий, находящихся в зоне рискованного земледелия; потеря сельхозугодий при расширении городов; недостаточное использование инновационных разработок, в частности дистанционного зондирования Земли, и т. д. (Pasko et al., 2022).

Часть проблем может быть решена организацией мониторинга территории сельхозугодий с помощью аэрокосмических средств, в том числе беспилотных летательных аппаратов (БПЛА) (Труфляк и др., 2022). К задачам, решаемым с их помощью, можно отнести: создание карт и учёт сельхозугодий, оценку качества посевных работ, мониторинг состояния и оценку урожайности, охрану сельхозугодий, оценку структуры и типа почв на поле, степень их деградации и др. (Пасько, Захарченко, 2020).

Современные технологии мониторинга больших и зачастую сложноконтурных полей позволяют получать точную и актуальную информацию, в том числе об их площади, рельефе, состоянии посевов, залесении, заболачивании и т. д. (Шагайда, Узун, 2017). Такая информация

представляется важным условием для оперативного и эффективного принятия управленческих решений в аграрном производстве. Заметим, что кроме положительного эффекта это направление имеет ограничения, связанные с правильным учётом характеристик цифровых камер, влиянием погодных условий (ветер, дождь), переездами между полями и т. д. Тем не менее применение БПЛА обладает множеством преимуществ перед традиционным пешим обследованием за счёт высокой мобильности, низкой стоимости работ, компактности оборудования, быстрого получения данных и высокого пространственного разрешения.

Многие исследования, связанные с применением изображений, получаемых с БПЛА, касаются задач изучения характеристик земли, почв, растительных ресурсов и их состояния (рост, развитие, повреждение, заболеваемость и т. д.) (Ковязин и др., 2022). Они решаются с помощью методов компьютерного зрения. Значительные по площадям сельскохозяйственные (с.-х.) поля в виде цифровых изображений представляют собой большие данные, так как они дополнительно связаны с метеорологическими параметрами, рельефом, свойствами почв, варьирующими от измерения к измерению. Поэтому в последнее время значительное внимание уделяется анализу больших данных с использованием нейронных сетей (элемент машинного обучения), направленному на решение задач, возникающих в результате реализации умного земледелия (Escamilla-Garcia et al., 2020; Ryan, 2019). Хотя машинное обучение в сельском хозяйстве достигло существенного прогресса в полученных результатах, несколько проблем остаются не полностью решёнными, например проблема оконтуривания с.-х. полей автоматизированным способом.

Разработка методик обработки изображений БПЛА продвинулась не так далеко, как разработка конструкции БПЛА (Биард, МакЛэйн, 2015) и измерительного оборудования. Решены задачи построения из большого набора изображений ортофотоплана (Лимонов, Гаврилова, 2018), который показывает исследуемое с.-х. поле целиком и даже в трёхмерном виде (Нехин, Олейник, 2011).

Настоящая статья стала продолжением исследований ранее начатых работ по применению изображений БПЛА в сельском хозяйстве для анализа состояния сельхозугодий методами компьютерного зрения (Катаев и др., 2018, 2021).

Обзор функций БПЛА в сельском хозяйстве

Беспилотный летательный аппарат (БЛА, БПЛА) — летательный аппарат без экипажа на борту (Фетисов, 2014). На современных видах БПЛА устанавливаются различного рода устройства, в том числе и цифровые камеры, позволяющие получать изображения поверхности земли в различных диапазонах длин волн (видимый, ближний инфракрасный и инфракрасный). Благодаря этому получаемые с помощью беспилотных летательных аппаратов измерения могут использоваться для решения целого спектра производственных задач (Беспилотные..., 2015). Применение БПЛА в сельском хозяйстве позволяет решать следующие задачи: инвентаризация сельхозугодий; оперативный мониторинг сельхозугодий; измерение объёмов собранного урожая; создание электронных карт полей, тематических карт земель сельхозназначения и состояния почвы, карт подверженности сельхозкультур болезням и вредителям, карт состояния и объёмов посевов и т. д.; экологический мониторинг земель; мониторинг земель сельхозназначения (Точное..., 2009).

Платформа дистанционного зондирования на основе БПЛА

Технология дистанционного зондирования с помощью аэрокосмических средств позволяет решать разнообразные задачи выделения с.-х. полей и классификации растительных культур, определять их состояние и др. Проблемой спутниковых оптических технологий выступает облачность, которая перекрывает видимость полей и тем самым не позволяет получать необходимую информацию (Якушев и др., 2019). В этом плане перспективной технологией для мониторинга сельскохозяйственных угодий на всех технологических стадиях считается

использование БПЛА. Возможности этих летательных аппаратов позволяют достигнуть более высокой производительности в получении необходимой информации о с.-х. поле, чем это могут сделать специалисты. Высокое пространственное и временное разрешение изображений, получаемых с помощью БПЛА, позволяют выполнять мониторинг больших по площади с.-х. полей в разумные временные сроки (Савин и др., 2011).

Благодаря фиксации состояния растений на с.-х. поле и одновременному измерению географического положения с помощью GPS/ГЛОНАСС (*англ.* Global Positioning System, система глобального позиционирования; ГЛОНАСС — Глобальная навигационная спутниковая система) можно узнать положение на поле артефактов (зарастание сорняками, высокая увлажнённость и т. д.). Получаемая информация позволяет принимать своевременные решения для достижения определённой цели (например, экономической или агрономической). Современные конструктивные особенности БПЛА делают их способными переносить и получать RGB-изображения (R — *англ.* red, красный; G — *англ.* green, зелёный; B — *англ.* blue, синий), мультиспектральные, гиперспектральные или инфракрасные. Существуют разнообразные методы компьютерного зрения, которые по спектральным характеристикам позволяют выделять разного вида растительность на основе цветовых или текстурных параметров (Пластинин и др., 2007).

Среди многочисленных датчиков камеры RGB наиболее часто устанавливаются на БПЛА благодаря таким характеристикам, как лёгкий вес, высокое пространственное разрешение, высокая скорость измерений и структурированные по каналам RGB-данные. Типовые цифровые камеры имеют три спектральных канала: красный, зелёный и синий. Такие изображения чувствительны к изменениям окружающей среды, в частности к состоянию атмосферы (облачное или безоблачное небо), яркости солнечного света, углу падения, ветру, что сказывается на качестве получаемых изображений.

Мультиспектральные и гиперспектральные устройства получают существенно больше информации, чем RGB-камеры, но они также чувствительны к изменению условий окружающей среды, и кроме того, они обеспечивают получение больших по объёму данных, что усложняет и значительно увеличивает время обработки и анализа. Инфракрасные камеры также широко используются в качестве измерителей температуры поверхности и применяются в том числе в сельском хозяйстве. Они могут быть применены в любое время дня и ночи. В качестве датчика может быть использовано лазерное устройство, которое позволяет получать трёхмерные данные, применяемые для оценки высоты и состояния растений (Ткачева, Фаворская, 2015).

Выделение объектов на изображении

Обнаружение объектов с помощью технологий сегментации изображений БПЛА — важная задача в приложениях компьютерного зрения. Алгоритмы обнаружения объектов опираются не только на методы компьютерного зрения, но и на методы на основе нейронных сетей, и в частности на свёрточные нейронные сети (СНС). Сегментация БПЛА-изображения связана с пиксельным или блочным методом, что позволяет выделять на изображении с.-х. поля землю и различные типы растительных культур.

Наборы данных изображений БПЛА

Для методов компьютерного зрения нужны примеры изображений, полученных в разнообразных условиях, на которых происходит поиск различных вариантов параметров алгоритмов, позволяющих эффективно решать сельскохозяйственные задачи. Значительные по объёму наборы изображений БПЛА имеют решающее значение и для обучения моделей нейронных сетей. Эти наборы могут быть сформированы специалистами, занимающимися обработкой изображений БПЛА, или найдены в специально разрабатываемых наборах изображений. Для решения задач сельского хозяйства отмечается отсутствие наборов данных,

состоящих из изображений, включающих сельскохозяйственные угодья при изменении различных параметров атмосферы и роста растений. Один из самых известных наборов изображений БПЛА содержит около 10 000 снимков, полученных с помощью двух типов цифровых камер: RedEdge-M и Sequoia (Zhong et al., 2020).

Известно, что высота полёта БПЛА влияет на пространственное разрешение изображения (см/пиксель) и зависит от типов цифровых матриц, используемых в той или иной камере. Полёт БПЛА на малой высоте обеспечивает высокое пространственное разрешение, а на большой высоте — более низкое, что ограничивает точность сегментации, так как при этом в пиксель может попасть не один, а несколько типов поверхности (например, растение и земля). Высокое пространственное разрешение позволяет получать больше информации о растениях на поле, комковатости почвы, однако при этом увеличивается время обследования поля.

Обзор программ в области обработки изображений БПЛА

Программное обеспечение, необходимое для получения результатов обработки изображений БПЛА, связано с этапами получения изображения, как это показано на *рис. 1*.

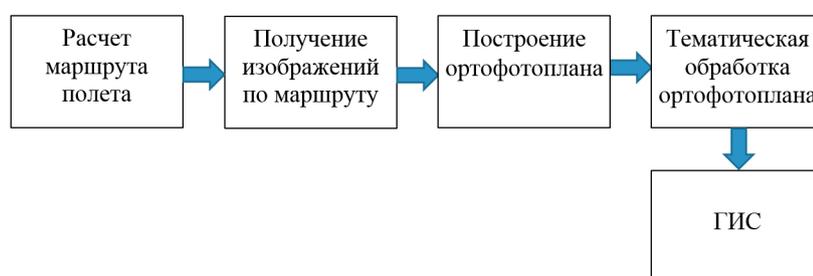


Рис. 1. Основные этапы работы, связанные с изображениями БПЛА

В работе (Тихонов, Акматов, 2018) приведён детальный обзор программ для обработки данных аэрофотосъёмки. Применение БПЛА для исследования некоторой территории (картографирование местности) представляет собой длительный процесс, который связан с получением большого набора изображений. При этом имеется чёткая последовательность этапов, которые необходимо выполнить для достижения результата (см. *рис. 1*). На первом этапе следует построить план полёта БПЛА по территории, которая может иметь сложную форму из-за присутствия на поле множества лесных околков (небольших участков леса) (*рис. 2*).



Рис. 2. Изображение исследуемой территории с помощью БПЛА

Для получения изображений в БПЛА используют цифровую камеру, которая должна делать снимки поверхности Земли с некоторым наложением одного на другое и с одновременной записью времени и географических координат центра изображения. Полученные во время полёта БПЛА снимки обрабатывают методами фотограмметрии (сшивка изображений) для получения единого изображения — ортофотоплана (см. *рис. 1*). Полученный ортофотоплан тематически обрабатывают специализированным программным обеспечением для решения тех или иных задач сельского хозяйства. Результаты обработки привязывают к географической системе выбранной геоинформационной системы (ГИС).

Среди разнообразия программного обеспечения для сшивки изображений имеется несколько популярных коммерческих продуктов. Одна из известных программ для сшивания изображений и создания трёхмерных изображений местности на основе вычисления сопряжённых точек между соседними снимками — Agisoft Photoscan (<https://www.agisoft.com>). Другой известный программный продукт для обработки изображений — Pix4D (<https://www.pix4d.com>), позволяющий сшивать большие наборы изображений и строить ортофотоплан. Заметим, что указанные программные средства — качественные, они позволяют с высокой точностью решать задачи сшивания изображений, однако имеют высокую стоимость.

Среди бесплатных программ можно выделить Image Composite Editor (ICE) (<https://www.microsoft.com/en-us/research/project/image-composite-editor>) — панорамный редактор изображений, разработанный Microsoft, в котором предусмотрено множество вариантов получения ортофотоплана. Продукты с открытым исходным кодом Hugin (<https://hugin.sourceforge.io>) и Opendronemap (<https://www.opendronemap.org>) позволяют разработчикам настраивать собственные версии программ.

Программное обеспечение, которое реализует тематическую обработку изображений (в том числе и сегментацию), позиционируется больше коммерческим, имеет высокую стоимость и распространяется только по крупным производителям сельскохозяйственной продукции. Существуют бесплатные программы, в которых встроены функции сегментации, например Image J (<https://imagej.softonic.ru>), Scilab (<https://www.scilab.org>) и другие, однако они имеют ограничения на виды методов сегментации и размер исследуемого изображения. Поэтому целью настоящей работы видится получение программы, по качеству сегментации сравнимой с ведущими программными продуктами. Среди ГИС-программ можно выделить очень популярные свободно распространяемые приложения QGIS (<https://www.qgis.org>), GRASS (<https://grass.osgeo.org>) и платную программу ArcGIS (<https://www.arcgis.com/index.html>).

Обзор свёрточных нейронных сетей

Компьютерное зрение (Гонсалес, Вудс, 2005) находится в постоянном развитии благодаря значительному прогрессу в сфере разработки высокоточных цифровых камер, методикам преобразования изображений и получения необходимой информации для практических целей (Wang, Ang, 2019). Ещё одно направление, в котором интенсивно развивается методика компьютерного зрения, — использование подходов нейронных сетей (Priya, 2019). Применение алгоритмов нейронных сетей в задачах компьютерного зрения позволяет сельскохозяйственным работникам решить одни и облегчить другие возникающие перед ними практические задачи. Нейронные сети (иначе — искусственные нейронные сети) (Хайкин, 2006) стали эффективным инструментом для обработки изображений, полученных с помощью БПЛА. Одной из разновидностей нейронных сетей выступают свёрточные нейронные сети — тип нейронной сети со специальной структурой (Головко, 2017). Типичная архитектура СНС состоит из трёх основных слоёв, первым из которых служит свёрточный слой, затем идёт слой пулинга и далее — полносвязная нейронная сеть. Роль первых двух слоёв заключается в поиске закономерностей во входных данных, тогда как последний слой отвечает за решение задачи классификации (Гафаров, Галимянов, 2018).

За последнее время разработано большое количество разновидностей СНС для решения задач компьютерного зрения, чему способствует простота разработки архитектуры объединения слоёв свёртки и пулинга, за которыми расположен набор полносвязных слоёв (Созыкин, 2017). Среди вариантов можно указать Spatial Exploitation-Based CNNs, CNN Based on Depth, CNNs with Multiple Paths, Feature-Map Exploitation Based CNNs, Multi-Connection Depending on the Width и др. (Bhatt et al., 2021).

В настоящей статье взята стандартная архитектура СНС, на входе которой находится RGB-изображение, а на выходе — классы выделяемых типов поверхности.

Выбор модели нейронной сети

Выбор модели СНС зависит от многих факторов, таких как время года получения изображений с.-х. поля, тип камеры, высота полёта, состояние атмосферы, объём получаемых данных и т. д. Любая нейронная сеть требует обучения, при этом обучающие данные становятся проблемой в плане объёма и качества, так как должны содержать не только информацию об объектах (типах поверхности) исследуемого с.-х. поля, но и типе цифровой камеры, а также об условиях получения изображений. Поэтому для приведения произвольных сложных необработанных данных в некоторое обобщённое состояние требуется предварительная обработка, которая как минимум включает: а) очистку данных от шума, б) корректировку яркости. Данные этапы обработки требуются для более высокой точности классификации типов поверхностей, так как в каждом пикселе или блоке пикселей хранится информация об исследуемом объекте. Если не учитывать весь набор предварительных операций, то можно столкнуться с проблемой чёткости выделения границ объектов на изображении.

На сегодняшний день при решении практических задач используется большое количество архитектур СНС. При выборе архитектуры нейронной сети следует обратить внимание на тип решаемой задачи. В настоящем исследовании рассматривается методика для решения задачи сегментации изображений, полученных с борта БПЛА, и для этого привлекается архитектура нейронной сети DeepLabV3+ (<https://github.com/VainF/DeepLabV3Plus-Pytorch>), в основе которой лежит алгоритм вейвлет-преобразования, и сеть Xception (<https://habr.com/ru/post/347564>), предназначенная для решения задач сегментации изображений. Нейронная сеть состоит из шести слоёв (без учёта входного слоя), и в каждом слое число нейронов равно 64, 128, 256, 512, 256 и 4 (выходной слой) соответственно.

Инструменты и методы

Сегментация изображений — одна из наиболее хорошо изученных технологий компьютерного зрения (Форсайт, Понс, 2004), цель которой заключается в присвоении каждому пикселю (или блоку как набору пикселей) изображения одного или более номеров, где каждый номер соответствует определённому классу объектов на изображении, выделенному по каким-то признакам (цвет, форма, текстура).

Для задачи, рассматриваемой в настоящей статье, при описании набора признаков объектов, которые связаны с растениями, землёй, околками, выбран только один признак — цвет. Отметим, что в большинстве задач применения БПЛА в сельском хозяйстве растения выступают неотъемлемой и преобладающей частью снимков БПЛА. Для постановки задачи сегментации растений на изображении, полученном с борта БПЛА, требуется выполнить общий анализ цветовых признаков растений (каналы (RGB), серое изображение или комбинации каналов (индексы)). Цветовые признаки растений зависят от большого количества сопутствующих элементов на изображении, таких как почва, освещённость, влажность и многие другие. Тем не менее, опираясь на результаты исследования (Kasajima, 2019), мы полагаем, что большое количество растений может быть индивидуально распознано в цветовом пространстве.

Программа обработки изображений, полученных с борта БПЛА, представляет собой совокупность отдельных модулей, связанных между собой последовательным их вызовом (см. *рис. 1*). На вход системы попадает изображение (примером служит *рис. 2*), на котором требуется выделить необходимый объект, которым в нашем случае выступает вспаханная земля. Далее изображение разбивается на блоки одинакового размера, например 50×50 пикселей. Этапами работы представляются обучение нейронной сети объекту, который необходим для исследования, и последующая обработка изображения (решение задачи сегментации всего изображения). На *рис. 2* нами условно выделено четыре класса объектов: вспаханное поле с прорастающей озимой пшеницей, земля, дорога и лесные околки. Для каждого объекта выделяются однородные блоки и рассчитываются цветовые характеристики на основе индекса

зольности Green (например, $Green = (2G - R - B)/(R + G + B)$). Таких блоков должно быть несколько, и размер их зависит от однородности выделяемого блока изображения.

Для получения информации, понятной на практике, необходимо привести пиксельную структуру блоков к метрической, для чего надо рассчитать пространственное разрешение на один пиксель по формуле:

$$R_x = 2H \frac{\text{tg}(\alpha_x/2)}{N_x},$$

где H — высота полёта БПЛА, см; α_x — поле зрения камеры (для DJI Mavic, которым проводилась съёмка, это 87°); N_x — количество пикселей на изображении по большой стороне ($(N_x \times N_y) = 4000 \times 3000$ пикселей).

С использованием приведённой выше формулы было получено пространственное разрешение пикселей на изображении для высоты полёта $H = 99$ м (для *рис. 2*), $R_x = 4,75$ см/пиксель. Тогда при разбиении изображения на блоки размером 5×5 м для пространственного разрешения R_x цифровой камеры будем иметь блок примерно 100×100 пикселей.

На *рис. 3* показаны блоки, на которых проходило обучение нейронной сети.

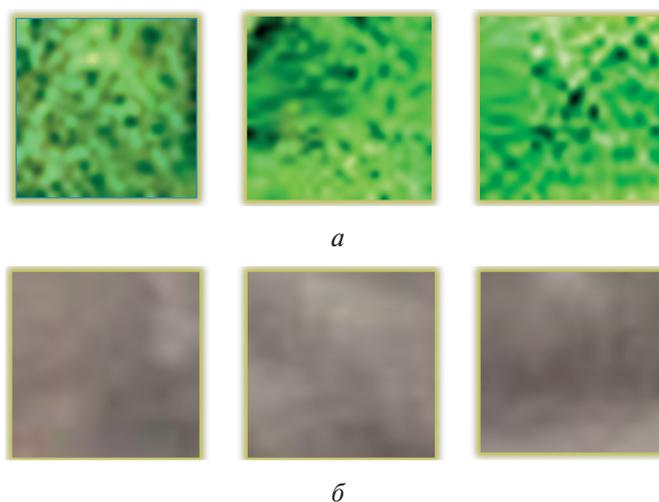


Рис. 3. Блоки изображения размером 10×10 м для обучения нейронной сети: *a* — для околков; *б* — для земли

Основные результаты и обсуждение

Для тестирования работы предложенного подхода из *рис. 2* была вырезана небольшая часть (*рис. 4a*, см. с. 62), чтобы был детально виден результат и можно было оценить точность. На *рис. 4б* показан результат работы нейронной сети по выделению лесных околков на *рис. 4a*.

На *рис. 5a* приведено изображение удаления околков и построение маски поля. На *рис. 5б* показан результат работы по оценке всхожести озимой пшеницы, когда было проведено обучение аналогичной нейронной сети, настроенной на три класса всхожести: слабая (50 % земли и 50 % зелени), средняя (25 и 75 %), слабая (10 и 90 %).

В *таблице* представлены результаты обучения нейронной сети в зависимости от объёма обучающей выборки (числа пикселей относительно блоков). Из данных *таблицы* видно, что точность сегментации лесных околков хуже, чем поля (92 % относительно 94 %).

На точность решения задачи сегментации влияет наличие тени деревьев, а также высокого разнообразия типов поверхности в блоке. Однако уменьшение размера блока приводит к увеличению времени обучения, что снижает вычислительную эффективность алгоритма. При расчёте точности проводилось обучение для 10000 эпох, и при этом функция потерь относительно начального значения изменялась примерно на порядок. После 8000 эпох кривая

функции потерь начинала выполаживаться, что говорит о достижении точки, близкой к конечной. Конечно, увеличение числа эпох обучения несколько улучшит точность решения задачи сегментации, однако мы считаем, что основные результаты, необходимые для понимания принципа работы нейронной сети в задаче сегментации, были достигнуты.

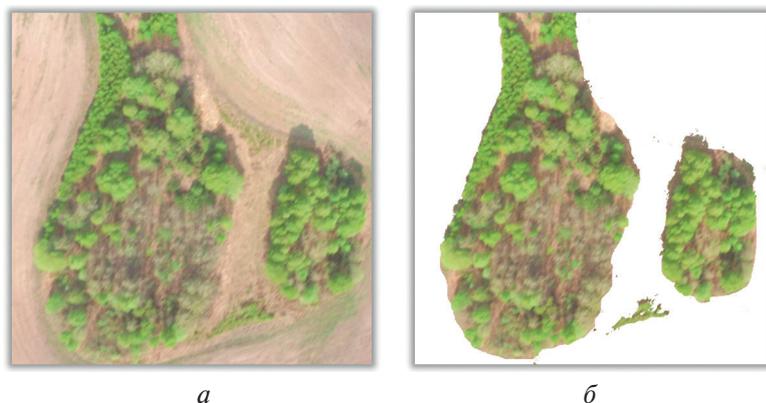


Рис. 4. Результат выделения с помощью нейронной сети лесных околков: *а* — исходное изображение; *б* — выделенные околки

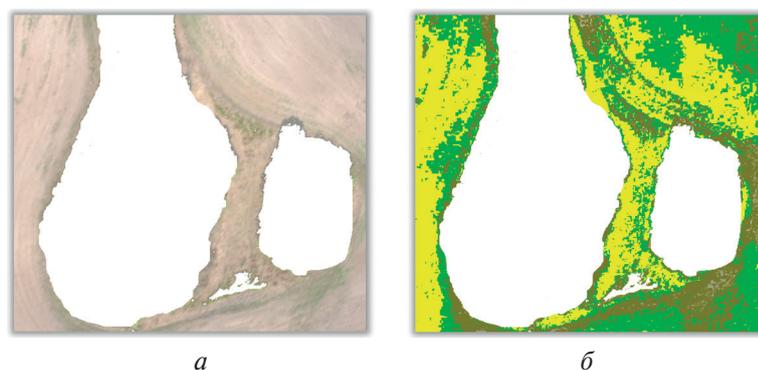


Рис. 5. Построение маски поля (*а*) и оценка уровня всхожести озимой пшеницы (*б*)

Результаты обучения нейронной сети в зависимости от объёма обучающей выборки с точностью распознавания объектов

Изображение	Часть от общего количества изображений блоков в обучающей выборке				
	1/5	2/5	3/5	4/5	Полная
	<i>Точность сегментации, %</i>				
Околки	56	63	77	85	92
Поле	69	76	84	90	94

Заключение

Получение изображений цифровыми камерами с помощью БПЛА и их обработка с использованием различных алгоритмов компьютерного зрения и с помощью нейронных сетей успешно применяются для выделения и идентификации с.-х. растений, определения их состояния и т. д. Кратко дан обзор задач, решаемых в сельском хозяйстве с использованием методов выделения контура с.-х. поля. Для выделения типов поверхности на поле рассмотрено реальное изображение, полученное с борта БПЛА для участка с.-х. поля в районе г. Томска 12 мая 2021 г.

Сложность выполнения сегментации вспаханного поля с прорастающей озимой пшеницей связана с наличием большого количества лесных околков. При решении задачи сегментации учтён тот факт, что обучающая выборка нейронной сети мала и состоит из однородных по типам поверхности участков изображения (см. рис. 3). Несмотря на малый объём выборки блоков на изображении для обучения и выполнение только 10 000 эпох обучения, получена точность сегментации, равная 94 %. Выполнена оценка уровня всхожести озимой пшеницы при обучении трём классам: слабой всхожести, средней и сильной, для которой точность составила 86 % при наборе обучающей выборки, насчитывающей всего 10 блоков изображений.

Литература

1. Беспилотные летательные аппараты: справоч. пособие. Воронеж: Науч. кн., 2015. 616 с.
2. Биард Р.У., МакЛэйн Т.У. Малые беспилотные летательные аппараты: теория и практика / пер. с англ. А.И. Демьяникова; под ред. Г.В. Анцева. М.: Техносфера, 2015. 312 с.
3. Гафаров Ф.М., Галимянов А.Ф. Искусственные нейронные сети и приложения: учеб. пособие. Казань: Изд-во Казанского ун-та, 2018. 121 с.
4. Головкин В.А. Нейросетевые технологии обработки данных: учеб. пособие / ред. В.А. Головкин, В.В. Краснопрошин. Минск: БГУ, 2017. 263 с.
5. Гонсалес Р.С., Вудс Р.Е. Цифровая обработка изображений / пер. с англ.; под ред. П.А. Чочиа. М.: Техносфера, 2005. 1072 с.
6. Катаев М.Ю., Ёлгин К.С., Сорокин И.Б. Методы технического зрения для картирования состояния сельскохозяйственных полей // Докл. Томского гос. ун-та систем управления и радиоэлектроники. 2018. Т. 21. № 4. С. 75–80. DOI: 10.21293/1818-0442-2018-21-4-75-80.
7. Катаев М.Ю., Карташов Е.Ю., Кузнецов А.А. Методика кластеризации с.-х. полей по RGB-изображениям беспилотных летательных аппаратов // Докл. Томского гос. ун-та систем управления и радиоэлектроники. 2021. Т. 24. № 3. С. 50–56. DOI: 10.21293/1818-0442-2021-24-3-50-56.
8. Ковязин В.Ф., Пасько О.А., Лепихина О.Ю., Трушников В.Е. Оценка точности инвентаризации лесных земель с применением воздушного лазерного сканирования // Геодезия и картография. 2022. № 6. С. 54–63. DOI: 10.22389/0016-7126-2022-984-6-54-63.
9. Лимонов А.Н., Гаврилова Л.А. Фотограмметрия и дистанционное зондирование. М.: Акад. проект, 2018. 297 с.
10. Нехин С.С., Олейник С.В. Автоматизация фотограмметрического сбора трехмерной информации на ЦФС // Изв. высш. учеб. заведений. Геодезия и аэрофотосъемка. 2011. № 2. С. 70–74.
11. Пасько О.А., Захарченко А.В. Кадастровые и геоэкологические характеристики особо ценных продуктивных сельскохозяйственных угодий // Изв. Томского политехн. ун-та. Инжиниринг георесурсов. 2020. Т. 331. № 11. С. 7–19. DOI: 10.18799/24131830/2020/11/2881.
12. Пластинин А.И., Куприянов А.В., Ильясова Н.Ю. Разработка методов формирования цвето-текстурных признаков для анализа биомедицинских изображений // Компьютерная оптика. 2007. Т. 31. № 2. С. 82–85.
13. Прогноз научно-технологического развития агропромышленного комплекса Российской Федерации на период до 2030 года / М-во сельского хоз-ва Российской Федерации. М.: НИУ ВШЭ, 2017. 141 с.
14. Савин И.Ю., Лупян Е.А., Барталев С.А. Оперативный спутниковый мониторинг состояния посевов сельскохозяйственных культур в России // Геоматика. 2011. № 2(11). С. 69–76.
15. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестн. Южно-Уральского гос. ун-та. Сер. «Вычислительная математика и информатика». 2017. Т. 6(3). С. 28–59. <https://doi.org/10.14529/cmse170303>.
16. Тихонов А.А., Акматов Д.Ж. Обзор программ для обработки данных аэрофотосъемки // Горный информационно-аналит. бюл. 2018. № 12. С. 192–198. DOI: 10.25018/0236-1493-2018-12-0-192-198.
17. Ткачева А.А., Фаворская М.Н. Моделирование трехмерных сцен лесных участков по данным лазерного сканирования и аэрофотоснимкам // Информационно-управляющие системы. 2015. Т. 6(79). С. 40–49. DOI: 10.15217/issn1684-8853.2015.6.40.
18. Точное сельское хозяйство / под ред. Д. Шпаара, А. Захаренко, В. Якушева. СПб.: Пушкин, 2009. 397 с.
19. Труфляк Е.В., Курченко Н.Ю., Креймер А.С. Мониторинг и прогнозирование в области точного сельского хозяйства по итогам 2021 г. Краснодар: КубГАУ, 2022. 210 с.
20. Фетисов В.С. Беспилотная авиация: терминология, классификация, современное состояние. Уфа: Изд-во «Фотон», 2014. 217 с.

21. *Форсайт Д. А., Понс Ж.* Компьютерное зрение. Современный подход: пер. с англ. А. В. Назаренко, И. Ю. Дорошенко. М.: Изд. дом «Вильямс», 2004. 928 с.
22. *Хайкин С.* Нейронные сети: полный курс. 2-е изд. / пер. с англ. Н. Н. Куссуль, А. Ю. Шелестова; под ред. Н. Н. Куссуль. М.: Изд. дом «Вильямс», 2006. 1104 с.
23. *Шагайда Н. И., Узун В. Я.* Тенденции развития и основные вызовы аграрного сектора России // Экономика с.-х. и перерабатывающих предприятий. 2017. № 9. С. 2–9.
24. *Якушев В. П., Дубенок Н. Н., Луян Е. А.* Опыт применения и перспективы развития технологий дистанционного зондирования Земли для сельского хозяйства // Современные проблемы дистанционного зондирования Земли из космоса. 2019. Т. 16. № 3. С. 11–23. DOI: 10.21046/2070-7401-2019-16-3-11-23.
25. *Bhatt D., Patel C., Talsania H.* CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope // Electronics. 2021. V. 10(20). Art. No. 2470. 28 p. <https://doi.org/10.3390/electronics10202470>.
26. *Escamilla-Garcia A., Soto-Zarazua G. M., Toledano-Ayala M., Rivas-Araiza E., Gastelum-Barrios A.* Applications of Artificial Neural Networks in Greenhouse Technology and Overview for Smart Agriculture Development // Applied. Sciences. 2020. V. 10(11). Art. No. 3835. 43 p. <https://doi.org/10.3390/app10113835>.
27. *Kasajima I.* Measuring plant colors // Plant Biotechnology. 2019. V. 36(2). P. 63–75. <https://doi.org/10.5511/plantbiotechnology.19.0322a>.
28. *Pasko O., Stauraskaya N., Zakharchenko A., Zharnikov V., Larionov Y.* Bio-Farming as the Basis of Environmentally-Sustainable Arable Farming at the Time of Global Warming // Research Anthology on Strategies for Achieving Agricultural Sustainability. 2022. P. 600–627. DOI: 10.4018/978-1-6684-5352-0.ch031.
29. *Priya S.* Identification of weeds using HSV color spaces and labelling with machine learning algorithms // Intern. J. Recent Technology and Engineering. 2019. V. 8(1). P. 1781–1786.
30. *Ryan M.* Agricultural Big Data Analytics and the Ethics of Power // J. Agricultural and Environmental Ethics. 2019. V. 33. P. 49–69. <https://doi.org/10.1007/s10806-019-09812-0>.
31. *Wang A. A., Zhang W., Wei X.* A review on weed detection using ground-based machine vision and image processing techniques // Computers and Electronics in Agriculture. 2019. V. 158. P. 226–240. DOI: 10.1016/j.compag.2019.02.005.
32. *Zhong Y., Hu X., Luo C.* WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H^2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF[J] // Remote Sensing of Environment. 2020. V. 250. 5 p. <https://doi.org/10.48550/arXiv.2012.13920>.

A technique for segmenting images of unmanned aerial vehicles using neural networks

М. Ю. Катаев¹, Е. Ю. Kartashov¹, В. В. Ryabukhin¹, Е. В. Makarov¹, О. А. Pasko²

¹ *Tomsk State University of Control Systems and Radioelectronics, Tomsk 634050, Russia*
E-mail: kmy@asu.tusur.ru

² *National Open Institute St. Petersburg, Saint Petersburg 197183, Russia*
E-mail: o.pasko@noironline.ru

Unmanned Aerial Vehicles (UAVs) have become widely known in various sectors of the economy, including agriculture. Basic advantages of UAVs are high speed, high spatial resolution (centimeters) and a large area of agricultural fields covered by the digital image (orthophotomap). Working with an orthophotomap helps reduce the proportion of routine work and reduces the time for specialists to monitor the state of agricultural plants. Significant technological progress in the development of UAV design tools, measurement techniques, software for processing of measurement results (images) has allowed creating a direction called “precision agriculture”. Processing of images obtained using UAVs is typically performed by computer vision methods or using neural networks. Convolutional Neural Networks (CNNs) have become the most popular type of neural networks in recent years. Despite the fact that CNN have become a powerful tool for solving a variety of UAV image processing problems, there are tasks that are not solved accurately enough using both computer vision methods and typical

CNN algorithms. The article provides a technique for segmenting images of agricultural fields obtained using UAVs using CNN. The problem solution features associated with small amount of data (images of homogeneous types of surface, for example, only soil) for training CNN are considered and obtained segmentation results are presented.

Keywords: unmanned aerial vehicle, UAV, image, convolutional neural network, segmentation

Accepted: 31.01.2023

DOI: 10.21046/2070-7401-2023-20-1-55-66

References

1. *Bespilotnye letatel'nye apparaty* (Unmanned aerial vehicles), Voronezh: Nauchnaya kniga, 2015, 616 p. (in Russian).
2. Beard R. W., McLain T. W., *Small Unmanned Aircraft: Theory and Practice*, Princeton, NJ: Princeton Univ. Press, 2012. 320 p.
3. Gafarov F. M., Galimyanov A. F., *Iskusstvennye neironnye seti i prilozheniya* (Artificial neural networks and applications), Kazan: Izd. Kazanskogo universiteta, 2018, 121 p. (in Russian).
4. Golovko V. A., Krasnoproshin V. V., *Neirosetevye tekhnologii obrabotki dannykh* (Neural network technologies of data processing), Minsk: BGU, 2017, 263 p. (in Russian).
5. Gonzalez R. C., Woods R. E., *Digital Image Processing, 2nd ed.*, Upper Saddle River, NJ: Prentice Hall, 2002, 185 p.
6. Kataev M. Yu., Elgin K. S., Sorokin I. B., Methods of technical vision for mapping the state of agricultural fields, *Doklady Tomskogo gosudarstvennogo universiteta sistem upravleniya i radioelektroniki*, 2018, Vol. 21, No. 4, pp. 75–80 (in Russian), DOI: 10.21293/1818-0442-2018-21-4-75-80.
7. Kataev M. Yu., Kartashov E. Yu., Kuznetsov A. A., Method of clustering agricultural fields by RGB images of unmanned aerial vehicles, *Doklady Tomskogo gosudarstvennogo universiteta sistem upravleniya i radioelektroniki*, 2021, Vol. 24, No. 3, pp. 50–56 (in Russian), DOI: 10.21293/1818-0442-2021-24-3-50-56.
8. Kovyazin V. F., Pasko O. A., Lepikhina O. Yu., Trushnikov V. E., Assessment of the forest land inventory accuracy using aerial laser scanning, *Geodezia i kartografiya*, 2022, Vol. 6, pp. 54–63 (in Russian), DOI: 10.22389/0016-7126-2022-984-6-54-63.
9. Limonov A. N., Gavrilova L. A., *Fotogrammetriya i distantsionnoe zondirovanie* (Photogrammetry and remote sensing), Moscow: Akademicheskii proekt, 2018, 297 p. (in Russian).
10. Nekhin S. S., Oleinik S. V., Automation of photogrammetric collection of three-dimensional information at the CFS, *Izvestiya vyshikh uchebnikh zavedenii. Geodeziya i aehrofotos'emka*, 2011, No. 2, pp. 70–74 (in Russian).
11. Pasko O. A., Zakharchenko A. V., Cadastral and geocological characteristics of especially valuable productive agricultural lands, *Bull. Tomsk Polytechnic University. Geo Assets Engineering*, 2020. Vol. 331, No. 11, pp. 7–19 (in Russian), DOI: 10.18799/24131830/2020/11/2881.
12. Plastinin A. I., Kupriyanov A. V., Il'yasova N. Yu., Development of methods for the formation of color-texture features for the analysis of biomedical images, *Komp'yuternaya optika*, 2007, Vol. 31, No. 2, pp. 82–85 (in Russian).
13. *Forecast of scientific and technological development of the agro-industrial complex of the Russian Federation for the period up to 2030*, Ministry of Agriculture of the Russian Federation, 2017, 140 p. (in Russian).
14. Savin I. Yu., Lupyan E. A., Bartalev S. A., Efficient space monitoring of crops in Russia, *Geomatika*, 2011, No. 2(11), pp. 69–76 (in Russian), <https://doi.org/10.14529/cmse170303>.
15. Sozykin A. V., Review of deep neural network training methods, *Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta. Ser. "Vychislitel'naya matematika i informatika"*, 2017, Vol. 6(3), pp. 28–59 (in Russian), DOI: 10.25018/0236-1493-2018-12-0-192-198.
16. Tikhonov A. A., Akmatov D. Zh., Review of programs for processing aerial photography data, *Gornyi informatsionno-analiticheskii byulleten'*, 2018, No. 12, pp. 192–198 (in Russian).
17. Tkacheva A. A., Favorskaya M. N., Modeling of three-dimensional scenes of forest areas according to laser scanning data and aerial photographs, *Informatsionno-upravlyayushchie sistemy*, 2015, Vol. 6(79), pp. 40–49 (in Russian), DOI: 10.15217/issn1684-8853.2015.6.40.
18. *Tochnoe sel'skoe khozyaistvo* (Precision Agriculture), Shpaar D., Zakharenko A. V., Yakushev V. P. (eds.), Saint Petersburg; Pushkin, 2009, 397 p. (in Russian).
19. Truflyak E. V., Kurchenko N. Yu., Kreimer A. S., *Monitoring i prognozirovanie v oblasti tochnogo sel'skogo khozyaistva po itogam 2021 g.* (Monitoring and forecasting in the field of precision agriculture based on the results of 2021), Krasnodar: KubGAU, 2022, 210 p. (in Russian).

20. Fetisov V. S., *Bespilotnaya aviatsiya: terminologiya, klassifikatsiya, sovremennoe sostoyanie* (Unmanned aviation: terminology, classification, current state), Ufa: Foton, 2014, 217 p. (in Russian).
21. Forsyth D. A., Ponce J., *Computer Vision. A Modern Approach*, Prentice Hall, 2002, 693 p.
22. Haykin S., *Neural Networks: A Comprehensive Foundation, 2nd ed.*, Upper Saddle River, NJ: Prentice Hall, 1999, 842 p.
23. Shagaida N. I., Uzun V. Ya., Development trends and main challenges of the agricultural sector of Russia, *Ekonomika sel'skokhozyaystvennykh i pererabatyvayushchikh predpriyatii*, 2017, No. 9, pp. 2–9 (in Russian).
24. Yakushev V. P., Dubenok N. N., Loupian E. A., Earth remote sensing technologies for agriculture: application experience and development prospects, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2019, Vol. 16, No. 3, pp. 11–23 (in Russian), DOI: 10.21046/2070-7401-2019-16-3-11-23.
25. Bhatt D., Patel C., Talsania H., CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope, *Electronics*, 2021, Vol. 10(20), Art. No. 2470, 28 p., <https://doi.org/10.3390/electronics10202470>.
26. Escamilla-Garcia A., Soto-Zarazua G. M., Toledano-Ayala M., Rivas-Araiza E., Gastelum-Barríos A., Applications of Artificial Neural Networks in Greenhouse Technology and Overview for Smart Agriculture Development, *Applied Sciences*, 2020, Vol. 10(11), Art. No. 3835, 43 p., <https://doi.org/10.3390/app10113835>.
27. Kasajima I., Measuring plant colors, *Plant Biotechnology*, 2019, Vol. 36(2), pp. 63–75, <https://doi.org/10.5511/plantbiotechnology.19.0322a>.
28. Pasko O., Staurskaya N., Zakharchenko A., Zharnikov V., Larionov Y., Bio-Farming as the Basis of Environmentally-Sustainable Arable Farming at the Time of Global Warming, *Research Anthology on Strategies for Achieving Agricultural Sustainability*, 2022, pp. 600–627, DOI: 10.4018/978-1-6684-5352-0.ch031.
29. Priya S., Identification of weeds using HSV color spaces and labelling with machine learning algorithms, *Intern. J. Recent Technology and Engineering*, 2019, Vol. 8(1), pp. 1781–1786.
30. Ryan M., Agricultural Big Data Analytics and the Ethics of Power, *J. Agricultural and Environmental Ethics*, 2019, Vol. 33, pp. 49–69 (in Russian), <https://doi.org/10.1007/s10806-019-09812-0>.
31. Wang A. A., Zhang W., Wei X., A review on weed detection using ground-based machine vision and image processing techniques, *Computers and Electronics in Agriculture*, 2019, Vol. 158, pp. 226–240, DOI: 10.1016/j.compag.2019.02.005.
32. Zhong Y., Hu X., Luo C., WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H^2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF[J], *Remote Sensing of Environment*, 2020, Vol. 250, 5 p., <https://doi.org/10.48550/arXiv.2012.13920>.