

УДК 528.88

## РАЗРАБОТКА РЕКОМЕНДАЦИЙ ПО АДАПТАЦИИ ЛУЧШИХ МИРОВЫХ ПРАКТИК ПРИМЕНЕНИЯ РЕЗУЛЬТАТОВ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ ДЛЯ РЕШЕНИЯ ПРОБЛЕМ В СЕЛЬСКОМ ХОЗЯЙСТВЕ РОССИИ

Е. В. Бутрова, В. А. Павлов, Д. В. Ковков

*Анализ современных научно-технических источников показывает, что для мониторинга состояний полей, контроля показателей урожайности, а также для улучшения бизнес-процессов агрокомпаний все чаще применяется анализ изображений сельскохозяйственных угодий. Важнейшим этапом такого анализа является автоматическое выделение полей на спутниковых снимках высокого разрешения. Обработка таких снимков может осуществляться с помощью алгоритмов глубокого машинного обучения. В данной работе приводятся результаты исследования работы трех различных архитектур сверточных нейронных сетей для выделения полей. Для анализа работы нейросетевых алгоритмов, детектированные регионы были сопоставлены с областями, ранее размеченными экспертами. Разработанные алгоритмы машинного обучения были обучены и протестированы на изображениях со спутника Landsat и данных из базы PlanetScope. Запуск сетей осуществлялся на графическом процессоре суперкомпьютера NVIDIA DGX-1, процесс обучения длился около 1 ч. Наибольшее значение коэффициента Серенсена, равное 0,75, удалось получить с помощью нейронной сети U-Net. Были также сформулированы рекомендации по использованию нейросетевых методов обработки данных дистанционного зондирования для цифровой трансформации сельскохозяйственной отрасли.*

**Ключевые слова:** дистанционное зондирование, сельское хозяйство, цветовые модели, сверточные нейронные сети, глубокое обучение.

### Введение

Использование цифровых технологий в различных индустриях является трендом мировой экономики последнего десятилетия. При внедрении цифровых технологий в сельское хозяйство большое внимание уделяется использованию данных дистанционного зондирования земной поверхности. Спутниковые изображения позволяют успешно решать следующие задачи:

- автоматической инвентаризации сельскохозяйственных угодий;
- прогнозирования урожайности;
- контроля выполнения работ механизаторов по равномерности засева.

Эти и другие задачи ранее решались путем осмотра сельскохозяйственных угодий [1].

В настоящее время сельскохозяйственная индустрия имеет набор инструментов для контроля угодий с помощью портативных метеостанций и земляных датчиков. Анализ этих данных в совокупности с данными дистанционного зондирования может способствовать предотвращению негативных сценариев повреждения посевов болезнями или вредителями, а также правильному выбору способа обработки сельскохозяйственных угодий и организации плана полевых работ [1].

На сегодняшний день данные дистанционного зондирования для полей позволяют получить ин-

формацию о равномерности развития сельскохозяйственных культур и наличии повреждений посевов болезнями или вредителями. Однако перед получением этой информации требуется выполнить важнейший этап предобработки спутникового снимка – выделение на нем сельскохозяйственных угодий.

Прогресс в области создания высокопроизводительных компьютеров с графическими ускорителями для обработки больших массивов данных позволил исследователям работать с глубокими нейронными сетями [2]. При решении современных задач классификации изображений или обнаружении на нем объектов подходы, основанные на использовании сверточных нейронных сетей, превосходят не только классические методы, но и в некоторых случаях даже экспертов в соответствующих областях [3].

Данная статья посвящена анализу работы глубоких нейронных сетей для выделения полей на спутниковых снимках, в которой описывается применение современных технологий в сельскохозяйственной отрасли; проводится обзор методов использования цветовых характеристик спутниковых снимков для выделения полей, а также мониторинга их состояния; описываются разработанные архитектуры сверточных нейронных сетей для детектирования сельскохозяйственных угодий, а также рассматриваются особенности обучения созданных моделей; представляются результаты чис-

ленных экспериментов для разработанных алгоритмов. И наконец, в заключении подводятся итоги исследования, а также даются рекомендации по применению в сельскохозяйственной отрасли России методов искусственного интеллекта к данным дистанционного зондирования земной поверхности.

#### Использование цветовых характеристик спутниковых изображений

Для анализа данных дистанционного зондирования нередко используются снимки с натуральной и ложной цветопередачей («True» и «False Color») [4].

Изображения с натуральной цветопередачей отображают спутниковые данные в видимом для человека спектре в реальном цвете. Данный формат отображения позволяет производить визуальный мониторинг сельскохозяйственных полей для определения границ поля и контроля процесса роста посевов. Пример такого изображения, полученный со спутника Landsat [5], представлен на рис. 1, а.

Изображения с ложной цветопередачей представляют собой цветные RGB-снимки без реальной цветопередачи. Они используются для выявления неоднородностей, которые сложно заметить на изображениях с натуральной цветопередачей. Пример такого изображения приведен на рис. 1, б. Оно показывает растительность в красном тоне, поскольку она отражает большую часть света в ближнем инфракрасном диапазоне. Изображения с ложной цветопередачей получают путем изменения формата кодирования каналов.

#### Использование сверточных нейронных сетей для анализа спутниковых изображений

Сверточные нейронные сети продемонстрировали свое превосходство при решении задач сегментации, классификации изображений, обнаружении объектов и распознавания сцены. Особенность таких сетей заключается в том, что дескрипторы изображений формируются алгоритмом самостоятельно, в процессе обучения [3]. В настоящее время почти все сложные задачи компьютерного зрения пытаются решить именно с помощью методов глубокого обучения [6, 7]. Одна из таких задач – автоматическое выделение сельскохозяйственных угодий на данных дистанционного зондирования земной поверхности для их дальнейшей обработки.

Большие возможности также открывает процесс объединения спутниковых данных с технологиями агро-интернета вещей: портативных метеостанций, земляных датчиков. Полученные таким образом данные по каждому из полей вкупе с примененными методами компьютерного зрения позволят, в частности, быстрее и точнее прогнозировать урожайность сельскохозяйственных угодий.

Для проведения сравнительного анализа различных алгоритмов выделения полей на спутниковых снимках были созданы три модели сверточных нейронных сетей, основанные на архитектурах U-Net [8], SegNet [9] и LinkNet [10]. Изучение работы этих моделей продолжает исследование, которое было представлено в работах [11, 12, 13, 19].




Рис. 1. Изображение с натуральной (а) и ложной цветопередачей (б)

Как показано на рис. 2, архитектура сети U-Net состоит из двух частей: кодировщика и декодировщика. Кодировщик представляет собой нейронную сеть с типичной архитектурой сверточной нейронной сети, состоящей из четырех блоков. Каждый такой блок состоит из двух сверточных слоев с ядром свертки  $3 \times 3$ , с примененной к каждому из них функцией активации ReLU, а также операции понижения дискретизации с функцией выбора максимума (maxpooling) с размером окна  $2 \times 2$  и шагом 2. Декодировщик содержит 3 блока. Каждый блок декодировщика состоит из операций повышения дискретизации (upsampling) и объединения с соответствующим набором признаков от кодировщика, двух сверточных слоев с ядром свертки  $3 \times 3$  и примененной к каждому из них функции активации ReLU. Последний слой сети выполняет операцию свертки с окном  $1 \times 1$  для соотношения каждого пикселя определенному классу.

Как и в случае с сетью U-Net, SegNet состоит из кодировщика, декодировщика и классифицирующего слоя. Архитектура этой модели показана на рис. 3. SegNet состоит из сверточных слоев (conv), операций пакетной нормализации (batch norm), функций активации ReLU, а также функций повышения (upsampling) и понижения (pooling) размерности. Все сверточные слои кодировщика соответствуют первым сверточным слоям сети VGG16 для классификации объектов [14]. Каждому блоку кодировщика соответствовал аналогичный блок декодировщика. Таким образом, декодировщик состоял из тех же слоев, что и кодировщик, за исключением применения операции понижения дискретизации с функцией выбора максимума, которая была заменена операцией повышения дискретизации. Классифицирующим слоем сети SegNet выступает слой с функцией softmax, который позволяет независимо предсказывать вероятности принадлежности каждого пикселя к тому или иному классу.

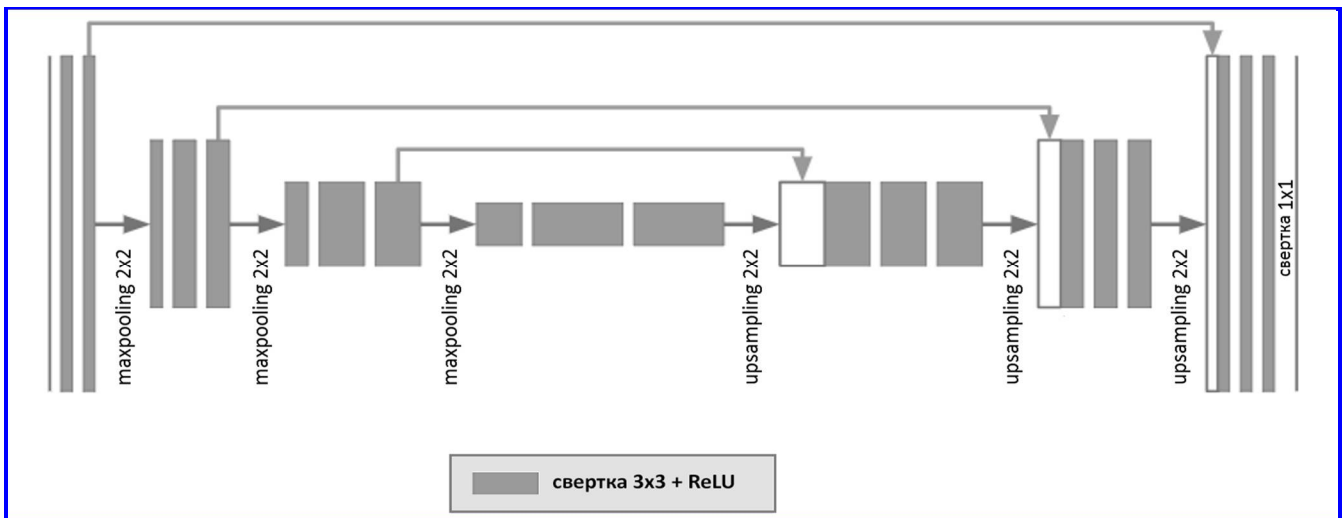


Рис. 2. Архитектура сети U-Net

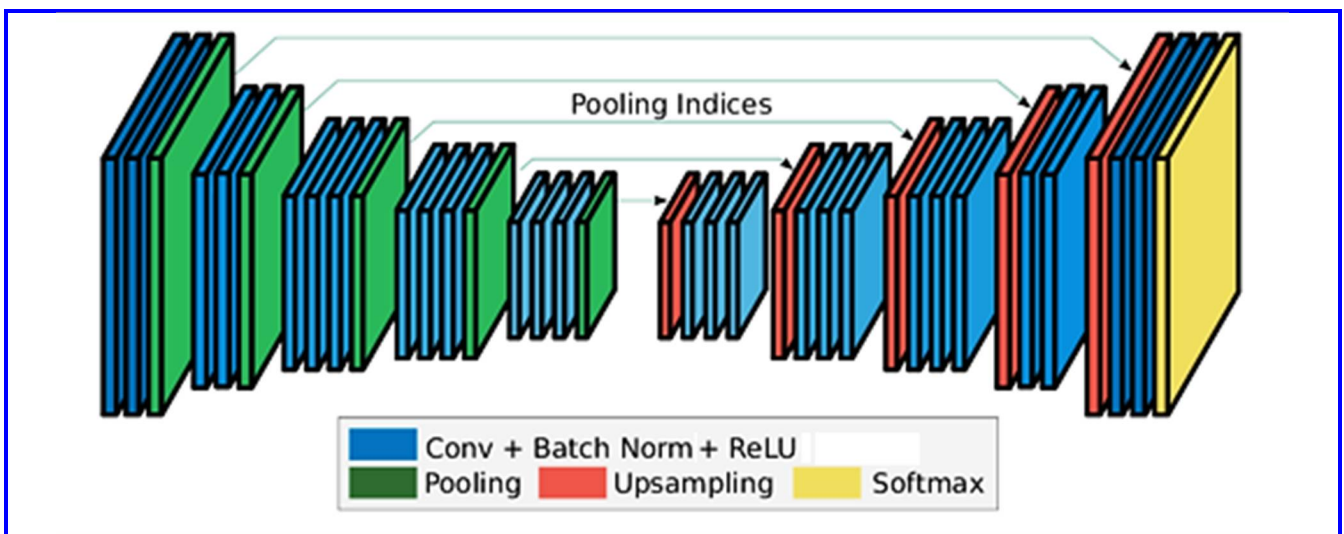


Рис. 3. Архитектура сети SegNet

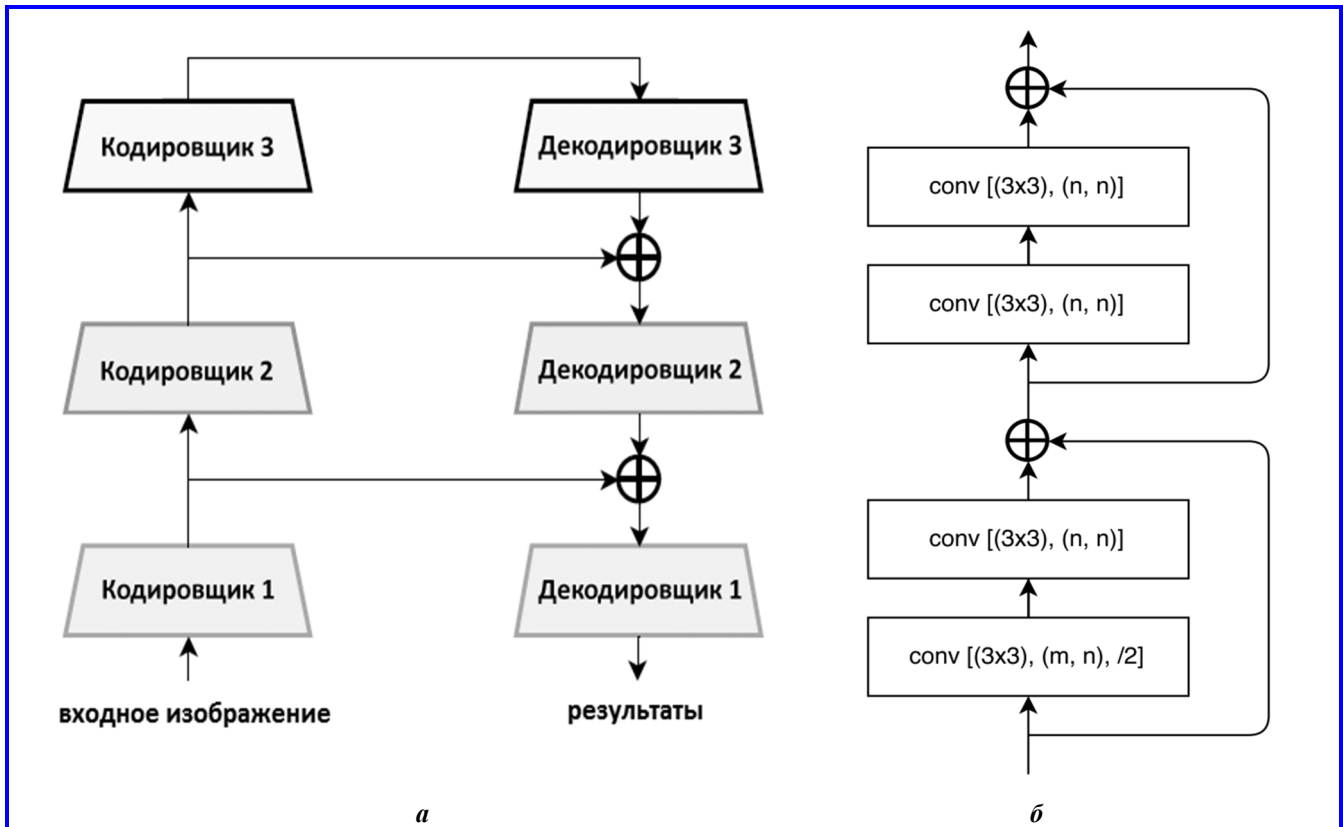


Рис. 4. TLinkNet: *a* – архитектура сети; *б* – схема кодировщика

Также была разработана сверточная нейронная сеть TLinkNet с LinkNet-подобной архитектурой на основе модели из [10]. Архитектура сети TLinkNet и схема кодировщика показаны на рис. 4. Разница между созданной TLinkNet и сетью из [10] заключается в отсутствии одного блока у кодировщика и декодировщика. Этот факт объясняется разницей в размере изображений, поступающих на вход соответствующим сетям. Как и описанные выше алгоритмы, TLinkNet имеет две части: кодировщик и декодировщик (см. рис. 4, *a*). Обе подсети состоят из 3 блоков. Каждый блок кодировщика содержит внутри себя сверточные слои, слои слияния признаков и операции понижения дискретизации с функцией выбора максимума (см. рис. 4, *б*). В соответствии со структурой блока кодировщика блок декодировщика имеет схожую архитектуру, за исключением применения операции понижения дискретизации, которая была заменена на операцию повышения дискретизации. Скорость обучения была равной  $10^{-3}$ . В качестве алгоритма численной оптимизации был выбран оптимизатор адаптивной оценки моментов (Adam). Эта функция использует значения моментов градиентов для поддержания скорости обучения, что повышает точность работы алгоритма машинного обучения [15]. В качестве

функции потерь была выбрана бинарная кросс-энтропия [16]. Классификатор заканчивал свое обучение после выполнения 256 эпох.

#### Результаты моделирования сверточных нейронных сетей

Для исследования работы алгоритмов детектирования полей использовались изображения со спутника Landsat [5] и данные PlanetScore. Изображения Landsat имеют пространственное разрешение 30 м/пиксель. Цветные RGB-снимки из PlanetScore, в отличие от изображений со спутника Landsat, имеют более высокое пространственное разрешение: 3 м/пиксель. Все данные были получены 25 июля 2018 г.

Обучение и тестирование разработанных алгоритмов проводилось на суперкомпьютере NVIDIA DGX-1, предоставленном центром искусственного интеллекта и цифровой экономики ЯрГУ [17]. Для оценки разработанных моделей использовался коэффициент подобия Серенсена (DSC), сравнивающий предсказанные и экспертные маски изображений. Этот показатель принимает значения из отрезка  $[0, 1]$  и фактически является двоичной мерой сходства двух множеств. Коэффициент Серенсена рассчитывается по следующей формуле:

$$DSC = 2I/S,$$

где  $I = |X \cap Y|$  – мощность пересечения, а  $S = |X| + |Y|$  – сумма мощностей экспертной разметки  $X$  и предсказаний  $Y$  [18]. Для поставленной задачи числитель  $I$  и знаменатель  $S$  можно вычислить по следующим формулам

$$I = \sum_{x \in X} \sum_{y \in Y} xy, S = \sum_{x \in X} (x + y),$$

где  $x, y \in [0, 1]$  – значения вероятностей принадлежности пикселей к тому или иному классу экспертной разметки  $X$  и предсказаний  $Y$  соответственно. Графики зависимости значения DSC от количества проделанных обучающих эпох ( $E$ ) показаны на рис. 5.

Согласно результатам тестирования, представленным в таблице, лучшие результаты сегментации спутниковых снимков показал алгоритм U-Net. Архитектуры TLinkNet и U-Net осуществляют передачу признаков от кодировщика к декодировщику в отличие от SegNet. Эта особенность позволяет использовать дополнительную полезную информацию из поступающих на вход данных. Недостатком использования сети U-Net является высокая вычислительная сложность процессов обучения и тестирования. Однако, следует заметить, что для сельскохозяйственных задач этот параметр не является критичным, так как в большинстве случаев они не требуют решения на мобильных аппаратных устройствах и/или получения результатов в режиме реального времени.

Примеры работы сети U-Net для обнаружения сельскохозяйственных угодий на спутниковых снимках из базы данных PlanetScore показаны на рис. 6.

### Заключение

Разработанные алгоритмы обнаружения полей на спутниковых снимках высокого разрешения основаны на реализации относительно нового подхода – глубокого обучения. В статье было показано, как сверточные нейронные сети, реализованные на современных графических процессорах и обученные на изображениях со спутника Landsat и данных PlanetScore, могут быть эффективно использованы для извлечения необходимых признаков на картинках. Коэффициент Серенсена (DSC) показывает разницу работы различных алгоритмов. Наибольшее значение DSC, равное 0,75, удалось получить с помощью сети U-Net.




Рис. 5. Графики зависимости коэффициента Серенсена от количества обучающих эпох для разработанных моделей нейронных сетей

Таблица

### Результаты численных экспериментов на снимках со спутника Landsat

Алгоритм	Коэффициент Серенсена (DSC)
SegNet	0,45
TLinkNet	0,68
U-Net	0,75



Рис. 6. Выделение сельскохозяйственных угодий на базе данных PlanetScore с помощью нейронной сети U-Net: а – спутниковый снимок; б – результат сегментации

Проведенное исследование позволяет также сформулировать дальнейшие рекомендации по использованию технологий глубоких нейронных сетей к данным дистанционного зондирования земной поверхности для цифровой трансформации сельскохозяйственной отрасли России:

1. Для детектирования полей на спутниковых изображениях следует применять передовые технологии глубокого обучения. Сверточные нейронные сети в сочетании с увеличением пространственного разрешения изображений способны извлекать очень точные данные о расположении сельскохозяйственных полей.

2. Большие возможности открывает процесс объединения спутниковых данных с технологиями агро-интернета вещей: портативных метеостанций, земляных датчиков. Больше данных по каждому из полей вкуче с методами компьютерного зрения и искусственного интеллекта позволят, в частности, более точно прогнозировать урожайность сельскохозяйственных угодий.

Таким образом, анализ данных дистанционного зондирования методами компьютерного зрения и машинного обучения позволит значительно повысить качество мониторинга состояний полей, а также упростить процессы ведения агробизнеса в России.

*Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 19-010-00619 «Разработка методологии применения результатов проекта «Цифровая Земля» для решения задач народного хозяйства и модель прогноза экономического эффекта их применения в контексте цифровизации России».*

### Литература

- Шагайда Н., Узун В. Тенденции развития и основные вызовы аграрного сектора России. Аналитический доклад / Н. Шагайда, В. Узун. – Текст : электронный // Центр стратегических разработок (ЦСР) : [сайт] – 2007. – URL: [https://www.csr.ru/wp-content/uploads/2017/11/Doklad\\_selskoe\\_hozyai-stvo\\_veb.pdf](https://www.csr.ru/wp-content/uploads/2017/11/Doklad_selskoe_hozyai-stvo_veb.pdf) (дата обращения: 01.05.19).
- Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах ; перевод с английского. – М.: ДМК Пресс, 2015. – 400 с.
- Шолле Ф. Глубокое обучение на Python / Перевод с английского. – СПб : Питер, 2018. – 400 с.
- High Spatial Resolution WorldView-2 Imagery for Mapping NDVI and Its Relationship to Temporal Urban Landscape Evapotranspiration Factors / H. Nouri, S. Beecham, S. Anderson [et al.] // Remote Sens. – 2014. – Vol. 6. – № 1. – P. 580 – 602.
- Landsat // USGS.gov. Science for a changing world : [сайт] – 2008. – URL: <https://www.usgs.gov/land-resources/nli/landsat>.
- Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль ; перевод с английского. – М. : ДМК Пресс, 2017. – 652 с.
- Николенко С. Глубокое обучение. Погружение в мир нейронных сетей / С. Николенко, А. Кадури, Е. Архангельская. – СПб : Питер, 2018. – 480 с.
- U-Net: convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // Medical Image Computing and Computer-Assisted Intervention (MICCAI). – 2015. – Vol. 9351. – P. 234 – 241.
- SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation / V. Badrinarayanan, A. Kendall, R. Cipolla // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2017. – Vol. 39. – № 12. – P. 2481 – 2495.
- LinkNet: Exploiting Encoder Representations for Efficient Semantic Segmentation / A. Chaurasia, E. Culurciello // IEEE Visual Communications and Image Processing (VCIP). – 2017. – P. 1 – 4.
- Deep learning for region detection in high-resolution aerial images / V. Khryashchev, A. Priorov, V. Pavlov [et al.] // Proceedings of 16th IEEE East-West Design & Test Symposium (EWDTS'2018). – 2018. – P. 792 – 796.
- Comparison of Different Convolutional Neural Network Architectures for Satellite Image Segmentation / V. Khryashchev, L. Ivanovsky, V. Pavlov [et al.] // Proceedings of the 23rd Conference of Open Innovations Association FRUCT'23. – 2018. – P. 172 – 179.
- Сравнительный анализ использования нейросетевых алгоритмов для сегментации объектов на спутниковых снимках / В. Павлов, В. Хрящев, А. Островская [и др.] // Цифровая обработка сигналов и ее применение (DSPA-2019): докл. 21-й междунар. конф. – 2019. – С. 399 – 403.
- Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition / K. Simonyan, A. Zisserman // ArXiv.org e-Print archive : [сайт]. – 2005. – URL: <https://arxiv.org/abs/1409.1556> (дата обращения: 10.04.2019).
- Kingma D. P., Ba J. Adam. A Method for Stochastic Optimization / D. P. Kingma, J. Adam Ba // ArXiv.org e-Print archive : [сайт] – 2005. – URL: <https://arxiv.org/abs/1412.6980> (дата обращения: 30.01.2019).
- A Tutorial on the Cross-Entropy Method / P. T. de Boer, D. Kroese, S. Mannor, R. Rubinstein // Annals of operations research. – 2005. – Vol. 134. – № 1. – P. 19 – 67.
- Центр искусственного интеллекта и цифровой экономики ЯрГУ : официальный сайт. – Ярославль. – URL: <http://demid.ai> (дата обращения: 10.03.2019).
- Rabie T. S. Implementation of some similarity coefficients in conjunction with multiple upgma and neighbor-joining algorithms for enhancing phylogenetic trees / T. S. Rabie // Egypt. Poult. Sci. – 2010. – Vol. 30. – P. 607 – 621.
- Building Detection on Aerial Images Using U-NET Neural Networks / L. Ivanovsky, V. Khryashchev, V. Pavlov [et al.] //

- Proceedings of the 24th Conference of Open Innovations Association (FRUCT). – 2019. – P. 116–122.
20. Concept development of control system for perspective unmanned aerial vehicles / V. Koryanov, T. Kokuytseva, A. Toporkov [et al.] // MATEC Web of Conferences. Conference on Mechanical and Aerospace Engineering (ACMAE 2017). – 2018. – Vol. 151. – P. 1–5.

Поступила в редакцию 21.05.2019

**Елена Викторовна Бутрова**, доцент, канд. техн. наук, e-mail: [evbutrova@gmail.com](mailto:evbutrova@gmail.com).  
(Российский университет дружбы народов).

**Владимир Александрович Павлов**, аспирант, e-mail: [vladimir@lpavlov.com](mailto:vladimir@lpavlov.com).  
(Ярославский государственный университет им. П.Г. Демидова).  
Т. 8 (495) 787-38-03.

**Джордж Владимирович Ковков**, кандидат технических наук, доцент,  
заместитель генерального директора по научной работе,  
т. 8 (495) 331-20-00, e-mail: [kovkov-dv@rudn.ru](mailto:kovkov-dv@rudn.ru).  
(ООО «Институт физико-технологических исследований»).

## DEVELOPMENT OF RECOMMENDATIONS ON ADAPTATION OF THE BEST INTERNATIONAL PRACTICES IN APPLICATION OF ERS DATA FOR SOLVING PROBLEMS IN RUSSIAN AGRICULTURE

**E. V. Butrova, V. A. Pavlov, G. V. Kovkov**

*The study of modern scientific and technical writings shows that the analysis of the images of agricultural lands is more and more frequently used for monitoring of the state of fields and yield indices, as well as improvement of business processes in agricultural companies. The most important stage of this analysis is the automatic identification of fields in high-resolution satellite images. Processing of such images can be performed using the deep machine learning algorithms. The article describes the results of studying the operation of three different architectures of convolutional neural networks for identification of fields. To analyze the operation of neural network algorithms, the detected regions were compared with the areas marked earlier by the experts. The developed machine learning algorithms were learnt and tested using the Landsat images and PlanetScope data. The networks were run on the graphics processor of the NVIDIA DGX-1 supercomputer, and the learning process lasted for 1 hour. The greatest value of the Sorensen coefficient equal to 0.75 was obtained using the U-Net neural network. The recommendations on using the neural network methods of processing ERS data for digital transformation of the agricultural industry were also formulated.*

**Key words:** remote sensing, agriculture, color models, convolutional neural networks, deep learning.

### References

1. Shagaida N., Uzun V. Trends in development and main challenges of the Russian agricultural sector. Analytical report / N. Shagaida, V. Uzun. – Text : electronic // Center for Strategic Research (CSR) : [web-site] – 2007. – URL: [https://www.csr.ru/wp-content/uploads/2017/11/Doklad\\_selskoe\\_hozyai-stvo\\_veb.pdf](https://www.csr.ru/wp-content/uploads/2017/11/Doklad_selskoe_hozyai-stvo_veb.pdf) (access date: 01.05.19).
2. Flach P. Machine Learning: The Art and Science of Algorithms That Make Sense of Data / P. Flach; translated from English. – M. : DMK Press, 2015. – 400 p.
3. Chollet F. Deep Learning with Python / Translated from English. – St. Petersburg : Piter Publishing House, 2018. – 400 p.
4. High Spatial Resolution WorldView-2 Imagery for Mapping NDVI and Its Relationship to Temporal Urban Landscape Evapotranspiration Factors / H. Nouri, S. Beecham, S. Anderson [et al.] // Remote Sens. – 2014. – Vol. 6. – No. 1. – P. 580–602.
5. Landsat // USGS.gov. Science for a changing world : [web-site] – 2008. – URL: <https://www.usgs.gov/land-resources/nli/landsat>.
6. Goodfellow I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville ; translated from English. – M. : DMK Press, 2017. – 652 p.
7. Nikolenko S. Deep learning. Immersing into the world of neural networks / S. Nikolenko, A. Kadurin, E. Arkhangelskaia. – St. Petersburg : Piter Publishing House, 2018. – 480 p.
8. U-Net: convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // Medical Image Computing and Computer-Assisted Intervention (MICCAI). – 2015. – Vol. 9351. – P. 234–241.
9. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation / V. Badrinarayanan, A. Kendall, R. Cipolla // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2017. – Vol. 39. – No. 12. – P. 2481–2495.
10. LinkNet: Exploiting Encoder Representations for Efficient Semantic Segmentation / A. Chaurasia, E. Culurciello // IEEE Visual Communications and Image Processing (VCIP). – 2017. – P. 1–4.

11. Deep learning for region detection in high-resolution aerial images / V. Khryashchev, A. Priorov, V. Pavlov [et al.] // Proceedings of 16<sup>th</sup> IEEE East-West Design & Test Symposium (EWDTS'2018). – 2018. – P. 792 – 796.
12. Comparison of Different Convolutional Neural Network Architectures for Satellite Image Segmentation / V. Khryashchev, L. Ivanovsky, V. Pavlov [et al.] // Proceedings of the 23<sup>rd</sup> Conference of Open Innovations Association FRUCT'23. – 2018. – P. 172 – 179.
13. Comparative analysis of using neural network algorithms for segmentation of objects in satellite images / V. Pavlov, V. Khriashchev, A. Ostrovskaia [et al.] // Digital processing of signals and its application (DSPA-2019): Proceedings of the 21<sup>st</sup> International Conference. – 2019. – P. 399 – 403.
14. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition / K. Simonyan, A. Zisserman // ArXiv.org e-Print archive : [web-site]. – 2015. – URL: <https://arxiv.org/abs/1409.1556> (access date: 10.04.2019).
15. Kingma D. P., Ba J. Adam. A Method for Stochastic Optimization / D. P. Kingma, J. Adam Ba // ArXiv.org e-Print archive : [web-site] – 2015. – URL: <https://arxiv.org/abs/1412.6980> (access date: 30.01.2019).
16. A Tutorial on the Cross-Entropy Method / P. T. de Boer, D. Kroese, S. Mannor, R. Rubinstein // Annals of operations research. – 2005. – Vol. 134. – No. 1. – P. 19 – 67.
17. Center for Artificial Intelligence and Digital Economy of the Yaroslavl State University : official web-site. – Yaroslavl. – URL: <http://demid.ai> (access date: 10.03.2019).
18. Rabie T. S. Implementation of some similarity coefficients in conjunction with multiple UPGMA and neighbor-joining algorithms for enhancing phylogenetic trees / T. S. Rabie // Egypt. Poult. Sci. – 2010. – Vol. 30. – P. 607 – 621.
19. Building Detection on Aerial Images Using U-NET Neural Networks / L. Ivanovsky, V. Khryashchev, V. Pavlov [et al.] // Proceedings of the 24<sup>th</sup> Conference of Open Innovations Association (FRUCT). – 2019. – P. 116 – 122.
20. Concept development of control system for perspective unmanned aerial vehicles / V. Koryanov, T. Kokuytseva, A. Toporkov [et al.] // MATEC Web of Conferences. Conference on Mechanical and Aerospace Engineering (ACMAE 2017). – 2018. – Vol. 151. – P.1 – 5.

**Elena Viktorovna Butrova**, Candidate of Technical Sciences (Ph. D), Associate Professor,  
e-mail: [evbutrova@gmail.com](mailto:evbutrova@gmail.com).

(Peoples' Friendship University of Russia (RUDN University)).

**Vladimir Aleksandrovich Pavlov**, Ph. D. Student, e-mail: [vladimir@lpavlov.com](mailto:vladimir@lpavlov.com).

Tel.: +7 (495) 787-38-03.

(Demidov Yaroslavl State University).

**George Vladimirovich Kovkov**, Candidate of Technical Sciences (Ph.D), Associate Professor,  
Deputy General Director for Science, tel.: +7 (495) 331-20-00,

e-mail: [kovkov-dv@rudn.ru](mailto:kovkov-dv@rudn.ru).

(JSC «Institute of Physico-technological Research»).