

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ТЕЛЕКОММУНИКАЦИИ
INFORMATION TECHNOLOGY AND TELECOMMUNICATIONS

УДК 519.677



DOI: 10.21822/2073-6185-2023-50-3-142-149

Оригинальная статья / Original article

**Моделирование процесса обучения нейросети DeepLabv3
для сегментации сельскохозяйственных полей**
А.Ф. Рогачев^{1,2}, И.С. Белоусов¹

¹Волгоградский государственный аграрный университет,

¹400002, г. Волгоград, пр. Университетский, 26, Россия,

²Волгоградский государственный технический университет,

²400005, г. Волгоград, пр. им. Ленина, 28, Россия

Резюме. Цель. Проведение мониторинга и определение состояния посевов в сельскохозяйственном производстве требует использование и совершенствование нейросетевых методов искусственного интеллекта. Целью исследования является создание математической модели процесса обучения нейросети DeepLabv3 для интеллектуального анализа и сегментации участков сельскохозяйственных полей. **Метод.** На основе сформированной базы RGB изображений сельскохозяйственных полей, размеченной на четыре класса, была разработана нейросеть архитектуры DeepLabv3 и проведено ее обучение. Получены аппроксимации кривой обучения модифицированной функцией Джонсона методами наименьших квадратов и наименьших модулей. **Результат.** Проведена статистическая оценка качества обучения и аппроксимации нейросетей архитектуре DeepLabV3 в сочетании с ResNet50. Построенное семейство DNN на основе DeepLabV3 с ResNet50 показали эффективность распознавания и достаточное быстродействие при определении состояния посевов. **Вывод.** Аппроксимация диаграммы обучения нейросетей архитектуре DeepLabV3, с использованием модифицированной функции Джонсона, позволяет оценивать значение «насыщения» моделируемой зависимости и прогнозировать максимальное значение метрики нейросети без учета возможного ее переобучения.

Ключевые слова: посевы сельскохозяйственных культур, задача сегментации, искусственные нейросети, математическое моделирование.

Для цитирования: А.Ф. Рогачев, И.С. Белоусов. Моделирование процесса обучения нейросети DeepLabv3 для сегментации сельскохозяйственных полей. Вестник Дагестанского государственного технического университета. Технические науки. 2023; 50(3):142-149. DOI:10.21822/2073-6185-2023-50-3-142-149

**Simulation of the of the DeepLabv3 neural network learning process
for the agricultural fields segmentation**

A. F. Rogachev^{1,2}, I.S. Belousov¹

¹Volgograd State Agricultural University,

¹26 Universitetsky Ave., Volgograd 400002, Russia,

²Volgograd State Technical University,

²28 Lenin Ave., Volgograd 400005, Russia

Abstract. Objective. Monitoring and determining the state of crops in agricultural production requires the use and improvement of neural network methods of artificial intelligence. The aim of the study is to create a mathematical model of the learning process of the DeepLabV3 neural network for intelligent analysis and segmentation of agricultural fields. **Method.** Based on the newly formed RGB database of images of agricultural fields, marked up into four classes, a neural network of the DeepLabV3 architecture was developed and trained. Approximations of the learning curve by the modified Johnson function are obtained by the methods of least squares and least modules. **Result.** A statistical assessment of the quality of training and approximation of neural networks to the DeepLabV3

architecture in combination with ResNet 50 was carried out. The constructed DNN family based on DeepLabV3 with ResNet50 showed the efficiency of recognition and sufficient speed in determining the state of crops. **Conclusions.** Approximation of the neural network learning diagram to the DeepLabV3 architecture, using a modified Johnson function, allows us to estimate the value of the “saturation” of the simulated dependence and predict the maximum value of the neural network metric without taking into account its possible retraining.

Keywords: crops, segmentation problem, artificial neural networks, mathematical modeling.

For citation: A. F. Rogachev, I. S. Belousov. Simulation of the of the DeepLabv3 neural network learning process for the agricultural fields segmentation. Herald of Daghestan State Technical University. Technical Science. 2023; 50(3):142-149. DOI:10.21822/2073-6185-2023-50-3-142-149

Введение. Дистанционное оценивание состояния сельскохозяйственных полей является достаточно трудозатратной задачей, учитывая их значительные площади [1]. Выявление биологического состояния агрофитоценозов в процессе их вегетации возможно методами искусственного интеллекта (ИИ). Для выявления мелиоративного состояния посевов, можно применять семантическую сегментацию по требуемым классам [2,3].

В качестве входных данных можно использовать цветные изображения, получаемые методами дистанционного зондирования, в частности БПЛА [4, 8]. Технологии дистанционного зондирования Земли широко используются в исследовании природной среды, мелиорации почв, метеорологии, и других сферах, наряду с беспилотными летательными аппаратами и искусственными спутниками Земли [4-7]. В точном земледелии прогнозы урожайности и данные о структуре насаждения является важными для оптимизации и корректировки структуры сельскохозяйственных посевов, а также обосновании субсидий сельхозтоваропроизводителям [10-14].

Постановка задачи. Решение задач семантической сегментации изображений агрополей обеспечивает прогнозирование урожайности и повышение качества управления сельскохозяйственным производством [8,9]. Формулирование и решению задачи семантической сегментации, является востребованной теорией и практикой агропромышленного производства. Создание и обучение глубоких нейронных сетей (DNN) сдерживается длительностью процессов их обучения, которая может составлять десятки часов даже при использовании современных графических средств GPU. Поэтому задача математического моделирования процесса обучения DNN для оценивания и прогнозирования показателей их эффективности является актуальной.

Имеется ряд научно-методических и прикладных проблем, включая выбор размеров и оптического разрешения изображений агрополей, обоснования оптимального сочетания гиперпараметров DNN для интеллектуальной поддержки принятия решений, требуют модификации известных и разработки новых подходов и решений, в том числе с использованием методов математического, статистического и компьютерного моделирования [25 - 27].

Методы исследования. Методические подходы к построению DNN основывались на рекомендациях А. Созыкина, изложенные в статье [22]. В качестве базы данных для сегментации использовались спектральные изображения участков сельскохозяйственных полей, полученные с помощью видеокамеры БПЛА. Исходные RGB-изображения размером 200x200 пикселей размечались по четырем классам, в которые входили вегетирующее поле, поле с дефектами развития, не засеянное поле, а также прочие объекты.

Рабочей гипотезой принималась возможность получения математического описания динамики обучения нейросети архитектуры DeepLabV3 ResNet50, с помощью аналитической функции. При обучении исследуемых нейросетей применялись известные критерии качества сегментации «Jaccard coefficient» (1)

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} . \quad (1)$$

Дополнительно использовались метрики «Intersection over Union» (IoU). Обучение нейросети осуществлялось с использованием графического ускорителя Nvidia RTX 2080Ti по технологии CUDA Toolkit 11.4. ИНС. Для повышения качества обучения в нейросетях применяли специальные слои регуляризации batch normalization, предложенные в 2015 году [23]. Как известно, обучение методом обратного распространения ошибки осуществляется быстрее в случае, когда обрабатываемые данные преобразованы к нормальному распределению, когда математическое ожидание равно нулю, а дисперсия равна единице [24]. При использовании метода стохастического градиентного спуска (SGD) нормализацию для каждого батча (пакета) можно выполнять отдельно с помощью mini-batch. Нормализованные значения $x_i \{ x_1, \dots, x_m \}$, рассчитывают по зависимости (2):

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}, \tag{2}$$

где μ_B - среднее значение в батче, σ - величина дисперсии, ϵ - малая константа. После этого выполняют масштабирование и смещение y_i согласно (3)

$$y_i = \gamma \hat{x}_i + \beta, \tag{3}$$

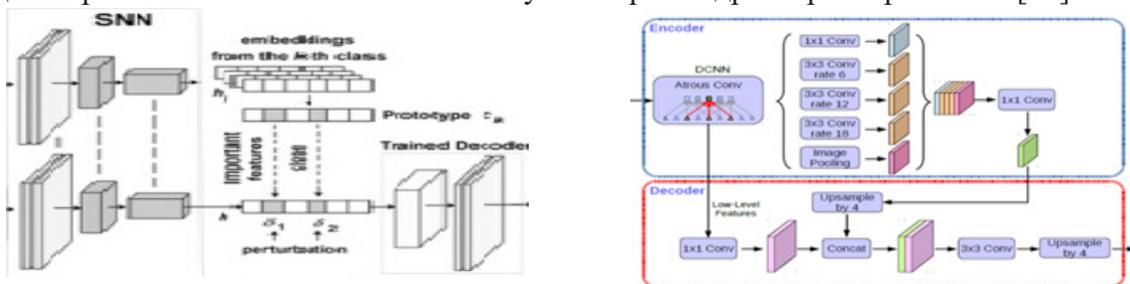
где γ и β - численные параметры, определяемые автоматически в процессе обучения нейросети.

Качество аппроксимации оценивалось по зависимостям, рекомендуемым, например, в [29]

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{Y}_i - Y_i| \tag{4}$$

$$MSE = \frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n} \tag{5}$$

Обсуждение результатов. В качестве архитектуры в экспериментах анализировались SNN-Net (а) и DeepLabV3 (б) (рис. 1). Архитектуры SNN-Net и DeepLabV3 используют каскады сверточных слоев. Обычно используют свертки ядрами размерами 3x3 [17].



а) б)
Рис. 1. Архитектуры сверточных сегментационных нейросетей:

а) SNN-Net; б) DeepLabV3

Fig. 1. Architectures of convolutional segmentation neural networks:

а) SNN-Net; б) DeepLabV3

Обе описываемые нейросети реализуют многократные уменьшения размеров изображений слоями свертки. Это позволяет сформировать сегментированный образ из изображений, построенных на различных стадиях преобразования исходных, которые объединяют с результатом, получаемым от backbone. Batch-нормализация позволяет стабилизировать процесс обучения, сократить количество эпох и, в конечном счете, времени обучения. В некоторых случаях, регуляризация с использованием batch-нормализации позволяет устранить негативное явление переобучения, что упрощает математическое описание динамики обучения нейросетей. Кроме того, применение batch-нормализации способствует решению проблемы «исчезающего градиента» [24].

Численные эксперименты проводились как для сжатых изображений, так и при помощи разделения исходных изображений на фрагменты 500x500 пикселей. Предварительно проведенные эксперименты показали, что модели DeepLabV3 ResNet50 и DeepLabV3 ResNet101

показывают преимущественное качество сегментации в сопоставлении с результатами, достигаемыми посредством модели FCN ResNet101. Типичные графики изменения функции потерь Loss в процессе обучения нейросети архитектуры DeepLabV3 представлены на рис. 2.

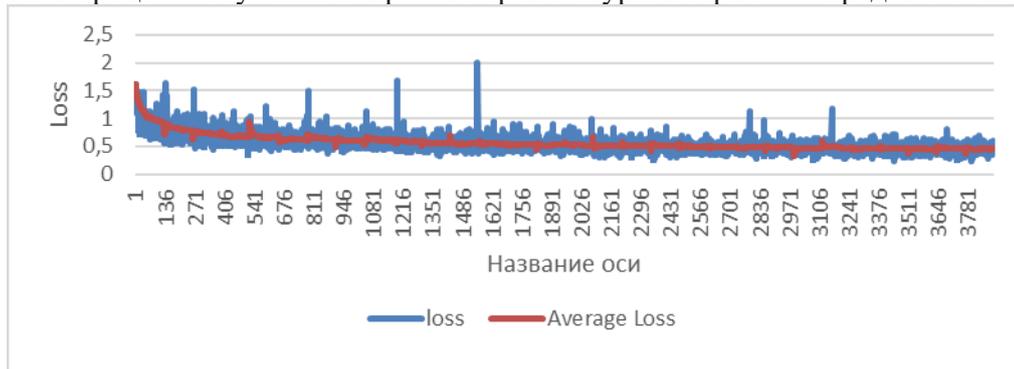


Рис.2. Типичные графики изменения функции потерь в зависимости от числа обработанных батчей изображений

Fig.2. Typical graphs of changes in the loss function depending on the number of processed image batches

Процесс обучения характеризуется относительно монотонными уменьшениями средних значений функции потерь (Average Loss) со значительными амплитудными скачками самой описываемой функции. Такой скачкообразный характер изменения показателей функции потерь при обработке различных батчей обусловлен использованием стохастического градиентного спуска и существенной неоднородностью цветографических параметров обрабатываемых цветных изображений участков сельскохозяйственных полей. Наибольшие значения Average Loss составляют 1.5 в начале процесса обучения.

После обработки примерно 4000 batches значения Average Loss падают до уровня 0.5 и стабилизируются без переобучения. Однако, представленная зависимость не очень наглядно характеризует процесс обучения разрабатываемой нейросети, поскольку в пределах каждой из эпох обработка отдельных пакетов только в совокупности определяет векторы изменения весовых коэффициентов нейронов обучаемой сети.

Более наглядное представление динамики и скорости процесса обучения нейросети по метрике «Jaccard score» в зависимости от числа эпох обучения, представлено на рис. 3.

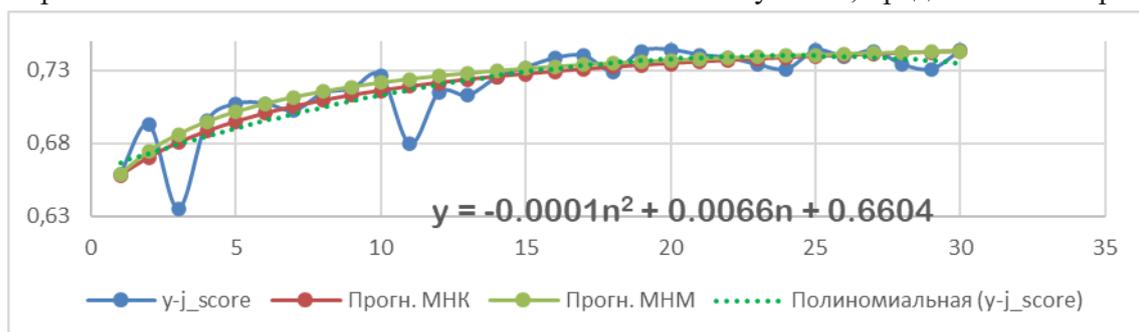


Рис. 3. Диаграмма обучения нейросети в зависимости от числа эпох, аппроксимированная различными методами

Fig. 3. Diagram of neural network training depending on the number of epochs, approximated by various methods

Для аппроксимации процесса обучения нейросети, который, при правильно подобранных гиперпараметрах, характеризуется «насыщением» (без переобучения), были исследованы различные математические зависимости, включая параболические, а также функции Джонсона (1), Торнквиста и другие [26].

$$y = P - a_1 / (a_2 + x), \quad (6)$$

где y – характеристический показатель моделируемого процесса;

P, a_1, a_2 – оцениваемые параметры; x – независимая переменная, характеризующая

текущее значение продолжительности моделируемого процесса.

Преимуществом зависимости (6) является наличие параметра P , представляющего собой значение «насыщения», которое в рассматриваемом случае характеризует оценку наибольшего значения метрики обучаемой нейросети при достаточно большом количестве эпох обучения. Результаты параметризации приведенных функций, выполненные численными методами наименьших квадратов (МНК) и наименьших модулей (МНМ)[28], например, встроенными в инструмент MS Excel, сведены в табл. 1.

Таблица 1. Параметры аппроксимирующих функций, полученные методами наименьших квадратов и наименьших модулей
Table 1. Parameters of approximating functions obtained by least squares and least modulus methods

Аппроксимирующая функция/ Approximation function	Модифицированная функция Джонсона/ Modified Johnson function		Парабола квадратичная/ Quadratic parabola
Метод оценки параметров Parameter estimation method	МНК	МНМ	МНК
P	0.765382	0.756506	-
a_1	0.8226842	0.522051	-0.0001
a_2	6.6671359	4.354997	0.0066
MSE	0.0136463	0.060165	0.10712194
MAE	0.0095585	0.008734	0.10180571

Анализ табл.1 показывает, что модифицированная функция Джонсона обеспечивает меньшие значения погрешностей аппроксимации по обоим критериям MSE и MAE. При этом параметры этой функции, определенные численными методами МНК и МНМ, близки между собой, что подтверждается близостью расположения расчетных значений, особенно в концах интервала (рис. 3). Отметим, что различие прогнозируемых предельных значений «насыщения» P , полученные в методах параметризации МНК и МНМ, незначительно и составляет всего 1.16%. Использование МНК дает несколько более высокое значение $P = 0.765382$, чем $P = 0.756506$, получаемое методом МНМ.

На основе разработанной нейросети создан SaaS сервис, интерфейс рабочего экрана которого визуализирует цветную маску, накладываемую на снимок изображения распознаваемого участка сельскохозяйственного поля. Применение исследованных сегментационных нейросетей позволило получить достаточно детализированные маски для заданных классов изображений участков сельскохозяйственных полей (рис. 4).

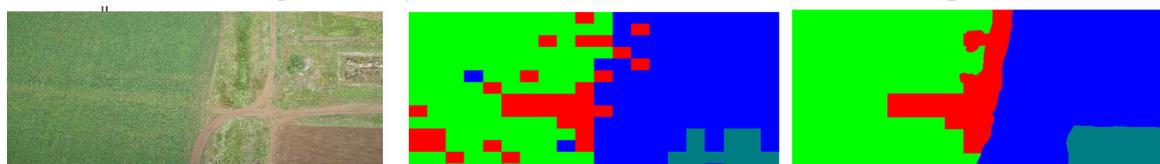


Рис. 4. Изображения участков сельскохозяйственных полей: а) исходное; б) размеченное; в) результат сегментации

Fig. 4. Images of areas of agricultural fields: a) original; b) marked; c) segmentation result

Полученные результаты нейросетевой сегментации показывают, что нейросети позволяют решать задачи интеллектуального распознавания развития посевов сельскохозяйственных культур, а также мелиоративного состояния участков полей. Отметим, что для повышения точности сегментации участков необходимо прежде всего совершенствовать обучающий dataset, включая его объем и сбалансированность по классам [8, 9].

Дальнейшее снижение погрешности возможно за счет увеличения объема и разрешения изображений, а также углубленной оптимизации гиперпараметров DNN, например, с применением программного обеспечения Keras Tuner, реализующего различные алгоритмы оптимизации [30].

Вывод. Аппроксимация диаграммы обучения нейросетей архитектуры DeepLabV3 с использованием модифицированной функции Джонсона, параметризуемой с помощью применения

МНК и МНМ, позволяет оценивать значение «насыщения» моделируемой зависимости и прогнозировать максимальное значение метрики нейросети без учета возможного ее переобучения. Необходимое повышение точности распознавания изображений участков сельскохозяйственных полей нейросетями моделей DeepLabV3 в сочетании с ResNet50 ограничивается недостаточным разрешением 200x200 пикселей, и возможными погрешностями ручной разметки изображений обучающей выборки.

Дальнейшее совершенствование архитектуры программы сегментации может быть обеспечено включением механизма «внимание» в архитектуру разрабатываемых нейросетей.

Благодарности. Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта №20-37-90142.

Acknowledgments. The study was carried out with financial support from the Russian Foundation for Basic Research within the framework of scientific project No. 20-37-90142.

Библиографический список

1. Saiz-Rubio V. From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. <https://www.mdpi.com/2073-4395/10/2/207/htm>.
2. A Review on Deep Learning Techniques Applied to Semantic Segmentation / Garcia-Garcia Alberto, Orts-Escolano Sergio, Oprea Sergiu, Villena-Martinez Victor, Garcia-Rodriguez Jose. <https://doi.org/10.48550/arXiv.1704.06857>.
3. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. <http://docs.cntd.ru/document/902361843>.
4. Bin Xu et al., "Remote sensing monitoring on dynamic status of grassland productivity and animal loading balance in Northern China," IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium, Anchorage, AK, USA, 2004, pp. 2306-2309 vol.4, doi: 10.1109/IGARSS.2004.1369747.
5. Pelletier, C.; Valero, S.; Inglada, J.; Champion, N.; Dedieu, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sens. Environ.* 2016, 187, 156–168.
6. L. Zhang, W. Yu, G. Li and H. Zhang, "An approach for flood inundated duration extraction based on Level Set Method using remote sensing data," 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016, pp. 1820-1822, doi: 10.1109/IGARSS.2016.7729467.
7. Zhao-Cheng Zeng, Yuan Wang, Thomas J. Pongetti, Fang-Ying Gong, Sally Newman, Yun Li, Vijay Natraj, Run-Lie Shia, Yuk L. Yung, Stanley P. Sander, Tracking the atmospheric pulse of a North American megacity from a mountaintop remote sensing observatory, *Remote Sensing of Environment*, Volume 248, 2020, 112000.
8. Рогачев А. Ф., Мелихова Е. В., Плещенко Т. В. Нейросетевая система управления программируемым аграрным производством с использованием ретроспективных данных и результатов дистанционного зондирования: монография. Волгоград: ФГБОУ ВО Волгоградский ГАУ, 2021. 172 с.
9. Рогачёв А. Ф. Математическое моделирование экономической динамики в аграрном производстве: монография. Волгоград, 2014. 172 с.
10. Соловьев Р. А., Тельпухов Д. В., Кустов А. Г. Автоматическая сегментация спутниковых снимков на базе модифицированной свёрточной нейронной сети UNET // Инженерный вестник Дона. 2017. № 4.
11. Jeong S, Ko J, Yeom J M. Predicting rice yield at pixel scale through synthetic use of crop and deep learning models with satellite data in South and North Korea[J]. *Science of The Total Environment*, 2021, 802(2):149726.
12. Xu J, Yang J, Xiong X, et al. Towards interpreting multi-temporal deep learning models in crop mapping[J]. *Remote Sensing of Environment*, 2021, 264:112599. <https://doi.org/10.3390/rs13224668>.
13. Ofori-Ampofo, S.; Pelletier, C.; Lang, S. Crop Type Mapping from Optical and Radar Time Series Using Attention Based Deep Learning. *Remote Sens.* 2021, 13, 4668.
14. Kussul N, Lavreniuk M, Skakun S, et al. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, PP(99):1-5..
15. Context-sensitive image analysis for coloring nature images / A. V. Alekseev, V. L. Rozaliev, Y. A. Orlova, A. V. Zaboloeva-Zotova // *Advances in Intelligent Systems and Computing*. 2016. V. 451. P. 133-141.
16. Deep residual learning for image recognition. K. He, X. Zhang, X. Ren, J Sun. *Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition. CVPR*. Las Vegas, Nevada, USA, 2016; 770-778.
17. Fezan Review DeepLabv3 (Semantic Segmentation). 2020. <https://medium.com/swlh/review-deeplabv3-semantic-segmentation-52c00ddb28d>.
18. Rosebrock Adrian. Intersection over Union (IoU) for object detection. <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection>.
19. Seeland M, Mäder P (2021) Multi-view classification with convolutional neural networks. *PLoS ONE* 16(1): e0245230. <https://doi.org/10.1371/journal.pone.0245230>
20. Sik-Ho Tsang Review: DeepLabv3. Atrous Convolution (Semantic Segmentation). <https://towardsdatascience.com/review-deeplabv3-atrous-convolution-semantic-segmentation-6d818bfd1d74>.
21. Rogachev A. F., Belousov I.S. Neural network identification of problem areas of the state of crops by methods of

- artificial intelligence. Proc. of the Lower Volga Agro-University Comp. 2022. 3(67). 459-466. DOI: 10.32786/2071-9485-2022-03-52.
22. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. (2017. Т. 6, № 3. С. 28–59. DOI: 10.14529/cmse170303.
 23. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. JMLR Workshop and Conference Proceedings. Proceedings of the 32nd International Conference on Machine Learning (Lille, France, July 06–11, 2015), 2015. vol. 37. pp. 448–456.
 24. He K., Zhang X., Ren S., et al. Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (Las Vegas, NV, USA, 27–30 June 2016), 2016. pp. 770–778. DOI: 10.1109/CVPR.2016.90.
 25. Гусейнов Р.В., Гусейнова М.Р., Алиева К.А. Некоторые вопросы многокритериальной оптимизации параметров сложных систем. Вестник Дагестанского государственного технического университета. Технические науки. 2023; 50(2): 67-75. DOI:10.21822/2073-6185-2023-50-2-67-75.
 26. Гришин А. Ф., Ягунов В. Н., Котов-Дарти С. Ф. Статистические модели в экономике. Ростов н/Д. : Феникс, 2005. 344 с.
 27. Курбанов С. А., Мелихова Е. В., Бородычев В. В., Рогачев А. Ф. Математико-статистическое моделирование урожайности корнеплодов при комбинированном орошении // Проблемы развития АПК региона. – 2018. – № 4(36). – С. 70-76. – DOI 10.15217/issn2079-0996.2018.4.70.
 28. Рогачев А.Ф. Параметризация эконометрических зависимостей методом наименьших модулей // Управление экономическими системами: электронный научный журнал. 2011. № 3. С. 0421100034.
 29. Gabriel Danilo Shimizu, Leandro Simões Azeredo Gonçalves. AgroReg: main regression models in agricultural sciences implemented as an R. Sci. Agric. v.80, e20220041, 2023. URL: <http://doi.org/10.1590/1678-992X-2022-0041>.
 30. Melikhova, E., Rogachev, A. Computer Optimization of ANN Hyperparameters for Retrospective Information Processing. In: Guda, A. (eds) Networked Control Systems for Connected and Automated Vehicles. Lecture Notes in Networks and Systems, (2023) vol 509. Springer, Cham. Pp. 723-730. https://doi.org/10.1007/978-3-031-11058-0_72.

References

1. Saiz-Rubio V. From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. <https://www.mdpi.com/2073-4395/10/2/207/htm>.
2. A Review on Deep Learning Techniques Applied to Semantic Segmentation / Garcia-Garcia Alberto, Orts-Escolano Sergio, Oprea Sergiu, Villena-Martinez Victor, Garcia-Rodriguez Jose. <https://doi.org/10.48550/arXiv.1704.06857>.
3. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. <http://docs.cntd.ru/document/902361843>.
4. Bin Xu et al., “Remote sensing monitoring on dynamic status of grassland productivity and animal loading balance in Northern China,” IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium, Anchorage, AK, USA, 2004, pp. 2306-2309 vol.4, doi: 10.1109/IGARSS.2004.1369747.
5. Pelletier, C.; Valero, S.; Inglada, J.; Champion, N.; Dedieu, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sens. Environ.* 2016;187:156–168.
6. L. Zhang, W. Yu, G. Li and H. Zhang, “An approach for flood inundated duration extraction based on Level Set Method using remote sensing data,” 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016;1820-1822, doi: 10.1109/IGARSS.2016.7729467.
7. Zhao-Cheng Zeng, Yuan Wang, Thomas J. Pongetti, Fang-Ying Gong, Sally Newman, Yun Li, Vijay Natraj, Run-Lie Shia, Yuk L. Yung, Stanley P. Sander, Tracking the atmospheric pulse of a North American megacity from a mountaintop remote sensing observatory, *Remote Sensing of Environment*, 2020; 248:112000.
8. Rogachev A.F., Melikhova E.V., Pleschenko T.V. Neural network control system for programmable agricultural production using retrospective data and remote sensing results: monograph. Volgograd: *Federal State Budgetary Educational Institution of Higher Education Volgograd State Agrarian University*, 2021; 172. (In Russ)
9. Rogachev A.F. Mathematical modeling of economic dynamics in agricultural production: monograph. Volgograd, 2014; 172. (In Russ)
10. Solovyov R. A., Telpukhov D. V., Kustov A. G. Automatic segmentation of satellite images based on a modified convolutional neural network UNET. *Engineering Bulletin of the Don*. 2017; 4.(In Russ)
11. Jeong S, Ko J, Yeom J M. Predicting rice yield at pixel scale through synthetic use of crop and deep learning models with satellite data in South and North Korea[J]. *Science of The Total Environment*, 2021, 802(2):149726..
12. Xu J, Yang J, Xiong X, et al. Towards interpreting multi-temporal deep learning models in crop mapping[J]. *Remote Sensing of Environment*, 2021, 264:112599. <https://doi.org/10.3390/rs13224668>.
13. Ofori-Ampofo, S.; Pelletier, C.; Lang, S. Crop Type Mapping from Optical and Radar Time Series Using Attention Based Deep Learning. *Remote Sens.* 2021;13:4668.
14. Kussul N, Lavreniuk M, Skakun S, et al. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017;(99):1-5.

15. Context-sensitive image analysis for coloring nature images. A. V. Alekseev, V. L. Rozaliev, Y. A. Orlova, A. V. Zaboloeva-Zotova // *Advances in Intelligent Systems and Computing*. 2016; 451:133-141.
16. Deep residual learning for image recognition. K. He, X. Zhang, X. Ren, J Sun. *Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition.CVPR*. Las Vegas, Nevada, USA, 2016; 770-778.
17. Fezan Review DeepLabv3 (Semantic Segmentation). 2020. <https://medium.com/swlh/review-deeplabv3-semantic-segmentation-52c00ddb28d>.
18. Rosebrock Adrian. Intersection over Union (IoU) for object detection. <https://www.pyimagesearch.com/2016/11/07/intersection-over-unioniou-for-object-detection>.
19. Seeland M, Mäder P (2021) Multi-view classification with convolutional neural networks. *PLoS ONE* 16(1): e0245230. <https://doi.org/10.1371/journal.pone.0245230>
20. Sik-Ho Tsang Review: DeepLabv3. Atrous Convolution (Semantic Segmentation). <https://towardsdatascience.com/review-deeplabv3-atrous-convolution-semantic-segmentation-6d818bfd1d74>.
21. Rogachev A. F., Belousov I.S. Neural network identification of problem areas of the state of crops by methods of artificial intelligence. *Proc. of the Lower Volga Agro-University Comp*. 2022; 3(67). 459-466. DOI: 10.32786/2071-9485-2022-03-52.
22. Sozykin A.V. Review of methods for training deep neural networks. *Bulletin of SUSU. Series: Computational mathematics and computer science*. 2017; 6(3): 28–59. DOI: 10.14529/cmse170303.
23. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *JMLR Workshop and Conference Proceedings*. *Proceedings of the 32nd International Conference on Machine Learning (Lille, France, July 06–11, 2015)*, 2015; 37: 448–456.
24. He K., Zhang X., Ren S., et al. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (Las Vegas, NV, USA, 27–30 June 2016)*, 2016; 770–778. DOI: 10.1109/CVPR.2016.90.
25. Guseinov R.V., Guseinova M.R., Alieva K.A. Some issues of multicriteria optimization of parameters of complex systems. *Herald of the Dagestan State Technical University. Technical Science*. 2023; 50(2): 67-75. DOI:10.21822/2073-6185-2023-50-2-67-75. (In Russ)
26. Grishin A.F., Yagunov V.N., Kotov-Darty S.F. Statistical models in economics. Rostov n/a. : Phoenix, 2005;344.(In Russ)
27. Kurbanov S. A., Melikhova E. V., Borodychev V. V., Rogachev A. F. Mathematical and statistical modeling of root crop yields under combined irrigation. *Problems of development of the regional agro-industrial complex*. 2018; 4(36):70-76. – DOI 10.15217/issn2079-0996.2018.4.70 .(In Russ)
28. Rogachev A.F. Parameterization of econometric dependencies by the method of least modules. *Management of Economic Systems: electronic Scientific Journal*. 2011; 3: 0421100034.
29. Gabriel Danilo Shimizu, Leandro Simões Azeredo Gonçalves. AgroReg: main regression models in agricultural sciences implemented as an R. *Sci. Agric*. v.80, e20220041, 2023. URL: <http://doi.org/10.1590/1678-992X-2022-0041>.
30. Melikhova, E., Rogachev, A. Computer Optimization of ANN Hyperparameters for Retrospective Information Processing. In: Guda, A. (eds) *Networked Control Systems for Connected and Automated Vehicles*. *Lecture Notes in Networks and Systems*, Springer, Cham. 2023;509:723-730. https://doi.org/10.1007/978-3-031-11058-0_72.

Сведения об авторах:

Алексей Фруминович Рогачев, профессор кафедры математического моделирования и информатики, rafr@mail.ru ORCID 0000-0002-3077-6622

Илья Станиславович Белоусов, аспирант кафедры математического моделирования и информатики; neznaukaknazvatmail@gmail.com ORCID 0000-0003-4415-8742

Information about authors:

Alexey F. Rogachev, Professor of the Department of Mathematical Modeling and Computer Science, rafr@mail.ru ORCID 0000-0002-3077-6622

Ilya S. Belousov, Graduate Student of the Department of Mathematical Modeling and Computer Science; neznaukaknazvatmail@gmail.com ORCID 0000-0003-4415-8742

Конфликт интересов/Conflict of interest.

Авторы заявляют об отсутствии конфликта интересов/The authors declare no conflict of interest.

Поступила в редакцию/ Received 05.08.2023.

Одобрена после рецензирования/ Reved 01.09.2023.

Принята в печать/ Accepted for publication 01.09.2023.