

УДК 004.93'1

В.В. Ганченко, А.А. Дудкин

Объединенный институт проблем информатики, Беларусь
ул. Сурганова, 6, г. Минск, 220012

СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ МОНИТОРИНГА СОСТОЯНИЯ СЕЛЬСКОХОЗЯЙСТВЕННОЙ РАСТИТЕЛЬНОСТИ ПО ДАННЫМ АЭРОФОТОСЪЕМКИ

V. Ganchenko, A. Doudkin

United Institute of Informatics Problems, Belarus
6, Surganova St., Minsk, 220012

CONVOLUTIONAL NEURAL NETWORKS IN TASKS OF AGRICULTURAL VEGETATION STATE MONITORING ON AERIAL IMAGES

В данной работе рассматривается задача распознавания состояния сельскохозяйственной растительности по данным аэрофотосъемки различного пространственного разрешения. В качестве основы для распознавания используется классификатор, позволяющий осуществлять классификацию входного изображения на три класса: «здоровая растительность», «пораженная растительность» и «почва». Предложенный классификатор строится из двух сверточных нейронных сетей, позволяющих выполнять классификацию на два класса: «здоровая растительность» и «пораженная растительность», «растительность» и «почва».

Ключевые слова: сверточная нейронная сеть, аэрофотосъемка, сельскохозяйственная растительность

In the article a recognition task of agricultural vegetation using aerial images of different spatial resolution is considered. An image classifier is proposed that allows classifying image segments into three classes: “healthy vegetation”, “diseased vegetation” and “soil”. This classifier is implemented by two convolution neural networks that previously form two classes of vegetation state: “healthy vegetation”-“diseased vegetation” and “vegetation”-“soil”.

Keywords: convolutional neural networks, aerial images, agricultural vegetation

Введение

Развитие точного земледелия предполагает наличие точной и оперативно обновляемой информации о состоянии растительности и почвы. Получение подобной информации возможно только при использовании дистанционного зондирования. Дистанционные методы мониторинга сельскохозяйственных полей дают возможность оперативно выявить пораженные болезнью участки растительности. Выявление заболевания на ранних стадиях развития позволяет оперативно и с минимальными затратами локализовать и вылечить заболевание. Выделяют два основных подхода к решению задачи выявления пораженных участков – спектрометрический и оптический [1-7]. Спектрометрический подход позволяет определять многие заболевания на ранних стадиях развития. Однако, этот подход требует наличия многоспектрального съ-

емочного оборудования, что не всегда возможно.

Использование беспилотных летательных аппаратов (БПЛА) является эффективным методом сбора данных на местах. Использование БПЛА в сельском хозяйстве быстро распространяется, т.к. является более дешевым при более высокой по сравнению со спутниками оперативностью [8-9]. БПЛА предоставляют визуальную информацию о больших площадях сельскохозяйственных культур максимально быстро, что позволяет руководителям хозяйств принимать оперативные решения. Полученные изображения затем могут быть импортированы в базу данных геоинформационной системы для дальнейшей обработки и анализа.

Одним из наиболее успешных методов, используемых при обработке аэрофотоснимков растительности, является использование искусственных нейронных сетей [10].

В данной статье используется подход, основанный на использовании сверточных нейронных сетей (СНС). Сверточные сети успешно используются при решении различных задач точного земледелия.

В работах [11-13] показано выделение сорняков на полях с точностью выше 90 % на данных, получаемых от робота, с использованием СНС как для классификации объектов, так и для семантической сегментации.

В [14] применены для классификации посевов (хотя они и составляют только часть искомых классов) по данным высотной аэрофотосъемки. При этом авторам удалось достичь точности около 89 %, что превышает аналогичные показатели для SVM.

Очень широкое применение СНС нашли и в задаче классификации заболеваний растительности. Так работы [15-18] описывают использование СНС для классификации аномалий развития и заболеваний различных культурных растений с точностью, превышающей 90 %. Однако основной проблемой этих работ является то, что классификация, позволяющая определить заболевание, требует наличия изображений отдельных листьев. Это значительно ограничивает применение результатов для получения карт пораженной растительности, т.к. подготовка таких карт требует оценки состояния растительной массы, а не каждого листа в отдельности.

Представленная работа фокусируется на распознавании участков растительности, состояние которой изменилось под влиянием заболевания. При этом классификация самого заболевания на таких участках на данном этапе не производится.

Объектом исследования являются цветные изображения сельскохозяйственных полей.

Цель работы состоит в разработке алгоритмов обработки цветных изображений растительных покровов, полученных с помощью цифровой съемки раз-

личного пространственного разрешения, а также их реализации в виде программных средств для систем компьютерного зрения.

Постановка задачи

Задачей исследования является разработка алгоритма преобразования $A: I_{orig} \rightarrow I_{result}$, позволяющего получить из исходного изображения сельскохозяйственного поля I_{orig} такое изображение I_{result} , каждый пиксель $I_{result}(x, y)$ которого получен из соответствующего пикселя изображения $I_{orig}(x, y)$, либо его окрестности. Каждый пиксель изображения I_{orig} соответствует точке в пространстве RGB. Каждый пиксель $I_{result}(x, y)$ соответствует одному из трех классов («здоровая растительность», «пораженная растительность» и «почва»).

Задачи классификации заболеваний растительности и поиска сорной растительности в данном исследовании не решались.

Материалами для исследований явились фотографии отдельных растений и экспериментального участка поля, засаженного картофелем. Последние выполнялись с высоты 5, 15, 50 и 100 метров [19-20]. Для получения данных небольшой участок поля был выделен при помощи четырех квадратных меток. Длина стороны квадрата равна одному метру, также на метку нанесены две черных линии шириной 20 см, при пересечении дающие крест. Наличие этих меток позволяет не только определять участок для исследований, но и вычислять пространственное разрешение снимков.

Наблюдению подвергались 3 группы растений: растения, зараженные болезнью из группы *alternaria*; растения, зараженные бактериальной болезнью *ergwinia*; здоровые растения (контрольная группа).

Исходные данные

Съемка растений проводилась ежедневно в 8, 10, 12, 14 и 16 часов на протяжении 8 дней июля.

В результате развития указанных заболеваний происходит разрушение хлорофилла в листьях картофеля, что приводит к изменению цвета растения. Необходимо отметить, что в ясную погоду созда-

ваемые солнцем блики на листьях также создавали эффект их пожелтения. Это вносило дополнительную ошибку при автоматической обработке.




Рис. 1. Примеры исходных аэрофотоснимков

Описание проблемы

Анализ цветовых характеристик различных типов объектов на базе их гистограмм показывает заметное их различие для почвы и растительности (для всех цветовых каналов), а также различие по синему каналу для здоровых и больных растений. К примеру, для изображений здоровой, пораженной заболеванием растительности и почвы на соответствующих гистограммах можно увидеть, что гистограмма почвы отличается от гистограмм растительности на каждом цветовом канале, а гистограммы каналов здоровой и пораженной растительности отличаются по форме.

Однако наличие в выделенном участке изображений объектов нескольких типов приводит к искажению нормализованной редуцированной гистограммы идеального типового объекта – смещение и искажение пика гистограммы.

Подобные искажения, а также значительное подобие цветовых характеристик здоровой и пораженной заболеванием растительности требуют информации о структуре изображений различных классов для их распознавания. Структурная информация может быть учтена при использовании СНС в качестве основы для алгоритма.

Классификатор «растительность–почва»

Классификатор «растительность–почва» *Ar:s* представляет собой сверточную нейронную сеть (СНС) [21], осуществляющую классификацию входного изображения на два класса «растительность» и «почва». В связи со значительными различиями в цветовых характеристиках этих двух классов данный классификатор не требует сложной структуры.

СНС имеет следующую структуру (параметры сети были выбраны эмпирически):

- Размер входного слоя: $33 \times 33 \times 3$.
- Сверточный слой Conv2D № 1: размер фильтра $F_s = 3$, количество фильтров $F_c = 4$, функция активации – ReLU.
- Conv2D № 2: $F_s = 3$, $F_c = 8$, ReLU.
- Полносвязный слой: количество нейронов = 16, ReLU.
- Выходной слой: количество нейронов = 2 (соответствуют классам «растительность» $A_{p;s}(C_p)$ и «почва» $A_{p;s}(C_s)$), функция активации – сигмоидная.

Функция потерь (loss) – softmax cross entropy [22].

Обучение:

- Размер обучающей выборки: 110528 изображений.
- Размер валидационной выборки: 27632 изображений (20 % общей базы).
- Результирующая точность на валидационной выборке: 96.9%.

Обучающая выборка была получена путем «нарезки» имеющихся аэрофотоснимков с размеченными участками. При этом нарезались участки размером 32, 64 и 128 пикселей с перекрытием и добавлением поворотов на углы, кратные 90° . Подготовленное изображение масштабировалось до размера, требуемого на вход сети.

Классификатор «здоровая–пораженная растительность»

Классификатор «здоровая–пораженная растительность» $A_{h;d}$ также представляет собой СНС, осуществляющую классификацию входного изображения на два класса «здоровая растительность» и «пораженная растительность». В связи со значительными различиями в цветовых характеристиках этих двух классов данный классификатор потребовал более сложной структуры.

СНС имеет следующую структуру (параметры сети также были выбраны эмпирически):

- Размер входного слоя: $33 \times 33 \times 3$.

- Conv2D № 1: $F_s = 3$, $F_c = 32$, функция активации – ReLU.
- Conv2D № 2: $F_s = 3$, $F_c = 32$, ReLU.
- Conv2D № 3: $F_s = 3$, $F_c = 32$, ReLU.
- Conv2D № 4: $F_s = 5$, $F_c = 64$, ReLU.
- Полносвязный слой № 1: количество нейронов = 128, ReLU.
- Полносвязный слой № 2: количество нейронов = 128, ReLU.
- Выходной слой: количество нейронов = 2 (соответствуют классам «здоровая растительность» $A_{h;d}(C_h)$ и «пораженная растительность»), функция активации – сигмоидная.

Функция потерь (loss) – softmax cross entropy.

Обучение:

- Размер обучающей выборки: 22244 изображений.
- Размер валидационной выборки: 5560 изображений (20 % общей базы).
- Результирующая точность на валидационной выборке: 93.8 %.

Объединение классификаторов

Т.к. требуется получить классификатор на три класса, то следует объединить полученные двухклассовые классификаторы в один.

Для этого воспользуемся тем, что классы «здоровая растительность» C_h и «пораженная растительность» C_d являются подклассами класса «растительность» C_p . Значение на выходе классификатора «растительность–почва» $A_{p;s}$, соответствующее классу «растительность» $A_{p;s}(C_p)$, находится в диапазоне $[0; 1]$ и может быть использовано в качестве коэффициента для выходов классификатора «здоровая–пораженная растительность» $A_{h;d}$.

Таким образом, искомый трехклассовый классификатор $A_{h;d;s}$ получает выходные значения принадлежности входного изображения I_{in} следующим образом:

1. Получить выходы $A_{p;s}(C_p)$ (растительность) и $A_{p;s}(C_s)$ (почва) классификатора $A_{p;s}$.

2. Получить выходы $A_{h;d}(C_h)$ (здоровая растительность) и $A_{h;d}(C_d)$ (пораженная растительность) классификатора $A_{h;d}$.
3. Получить выходы классификатора $A_{h;d;s}$ в виде:

$$\begin{cases} A_{h;d;s}(C_h) = A_{p;s}(C_p) \times A_{h;d}(C_h) \\ A_{h;d;s}(C_d) = A_{p;s}(C_p) \times A_{h;d}(C_d) \\ A_{h;d;s}(C_s) = A_{p;s}(C_s) \end{cases}$$

Алгоритм распознавания

В целом алгоритм распознавания (преобразование $A:I_{orig} \rightarrow I_{result}$) можно представить в следующем виде:

1. Загрузить исходное цветное изображение I_{orig} размером $M \times N$.
2. Для $\forall(x, y): x \in [0, M - 1], y \in [0, N - 1]$:
 - 2.1. Получаем окрестность $O(I_{orig}(x, y))$ пикселя в позиции (x, y) в виде цветного изображения размером 33×33 пикселя.
 - 2.2. Подаем полученное изображение $O(I_{orig}(x, y))$ на классификаторы $A_{p;s}$ и $A_{h;d}$.
 - 2.3. Выходные значения классификаторов $A_{p;s}$ и $A_{h;d}$ используем для вычисления выходов общего классификатора $A_{h;d;s}$.
 - 2.4. Получаем индекс класса: $index = \operatorname{argmax}([A_{h;d;s}(C_h), A_{h;d;s}(C_d), A_{h;d;s}(C_s)])$;
 - 2.5. Присваиваем пикселю выходного изображения $I_{result}(x, y)$ значение, соответствующее псевдоцвету индекса класса: светло-серый – здоровая растительность, белый – пораженная растительность, темно-серый – почва.
3. Сохраняем полученное изображение I_{orig} .

Тестирование

Тестирование объединения классификаторов осуществлялось на общей базе изображений классов: обучающая + валидационная выборка. При этом оценивалась точность классификации для каждого класса в отдельности. Полученные

результаты тестирования приведены в табл. 1.

Таблица 1. Результаты тестирования объединения классификаторов

Класс	Точность, %
Пораженная растительность	74.29
Здоровая растительность	90.16
Почва	99.03

Наибольшее количество ошибок возникало на участках, соответствующих границе здоровой растительности и почвы (в особенности в местах, где небольшие участки почвы окружены растительностью, создающей на этом участке почвы тень; см. табл. 2).

Таблица 2. Оценка количества ошибок

Класс	Ошибка I, %	Ошибка II, %
Пораженная растительность	25.71	10.69
Здоровая растительность	9.84	10.66
Почва	0.97	15.17

Полученная при тестировании распознавания точность – 75-84 % в зависимости от разрешения снимка, освещения на нем и количества «пятен» почвы в растительной массе.

Выводы

Предложен и реализован с использованием библиотеки Tensorflow алгоритм распознавания состояния растительности на базе двух СНС по данным аэрофотосъемки. Предложенный алгоритм позволяет снизить влияние шумовых факторов (освещение, солнечные блики) на качество получаемых карт пораженной растительности за счет использования СНС. При этом использование двух СНС позволило снизить искажение цветовых характеристик изображений окрестностей пикселей при попадании в него растительности и почвы.

Дальнейшие исследования предполагают наличие нейросетевого детектирования для выделения посторонних предметов, а также нейросетевой семан-

тической сегментации для исключения необходимости дополнительного алгоритма и снижения количества ошибок в проблемных областях.

Литература

1. Беляев, Б.И. (2006) Оптическое дистанционное зондирование. Минск: БГУ. 455 с.
2. Шовенгердт, Р.А. (2013) Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера. 592 с.
3. Chao, K. (2002) Machine vision technology for agricultural applications. *Elsevier science transactions on computers and electronics in agriculture*. Vol. 36. P. 173-191.
4. Kumar, N. (2004) *Do leaf surface' characteristics affect agrobacterium infection in tea [camellia sinensis (1)]*. Vol. 29, № 3. P. 309-317.
5. Wu, L. (2009) Identification of weed, corn using BP network based on wavelet features and fractal dimension. *Scientific Research and Essay*. November, 2009. – Vol. 4 (11). – P. 1194-1400.
6. Qin, Zh. (2005) Detection of rice sheath blight for in-season disease management using multispectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*. Vol. 7. P. 115-148.
7. Aksoy, S. (2010) Automatic mapping of linear woody vegetation features in agricultural landscapes using very high-resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*. № 48 (1, 2). P. 511-522.
8. Abdullahi, H.S. (2017) Advances of image processing in Precision Agriculture: Using deep learning convolution neural network for soil nutrient classification. *Journal of Multidisciplinary Engineering Science and Technology (JMEST)*. Vol. 4, Issue 8. P. 7981-7987.
9. Wright, D., Rasmussen, V., Ramsey, R., Baker, D., Ellsworth, J. (2004) Canopy Reflectance Estimation of Wheat Nitrogen Content for Grain Protein Management. *GIScience Remote Sens*. Vol. 41, No. 4. P. 287–300.
10. Mate, K.A., Pooja, G., Kavita, S.R. (2016) Feature Extraction Algorithm for Estimation of Agriculture Acreage from Remote Sensing Images. P. 5–9.
11. Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Zhang, L. (2018) A fully convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery. *PLoS ONE* 13(4): e0196302.
12. Sa, I. (2018) WeedNet: Dense Semantic Weed Classification Using Multispectral Images and MAV for Smart Farming. *IEEE Robotics and Automation Letters*. Vol. 3(1). P. 588-595.
13. Potena, C., Nardi, D., Pretto, A. (2017) Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture: Intelligent Autonomous Systems. P. 105-121.
14. Yao, C., Zhang, Y., Zhang, Y., Liu, H. (2017) Application of convolutional neural network in classification of high resolution agricultural remote sensing images, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLII-2/W7. P. 989-992.
15. Atole, R.R., Park, D. (2018) A Multiclass Deep Convolutional Neural Network Classifier for Detection of Common Rice Plant Anomalies. *IJACSA: International Journal of Advanced Computer Science and Applications*. Vol. 9, No. 1. P. 67-70.
16. Rajmohan, R., Pajany, M., Rajesh, R., Raman, D.R., Prabu, U. (2018) Smart paddy crop disease identification and management using deep convolution neural network and SVM classifier. *International Journal of Pure and Applied Mathematics*. Vol. 118, No. 15. P. 255-264.
17. Athanikar, G., Badar, P. (2016) Potato Leaf Diseases Detection and Classification System. *International Journal of Computer Science and Mobile Computing*. Vol. 5 Issue, 2. P. 76-88.
18. Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., Stefanovic, D. (2016) Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*. 11 p.
19. Sobkowiak, B. (2006) Zastosowanie technik analizy obrazu do wczesnego wykrywania patogenow ziemniaka. Praca nie publicowana. Poznan: PIMR.
20. Sobkowiak, B. (2007) Zastosowanie technik analizy obrazu do wczesnego wykrywania zarazy ziemnechanej w warynkach polowych. Praca nie publicowana. Poznan: PIMR.
21. Николенко, С., Кадурич, А., Архангельская, Е. (2018) Глубокое обучение. СПб.: Питер. 480 с.
22. Tensorflow API documentation. Available from: https://www.tensorflow.org/api_docs/python/tf/n/softmax_cross_entropy_with_logits_v2

References

1. Belyayev, B.I. (2006) *Opticheskoye distantsionnoye zondirovaniye*. Minsk: BGU. 455 s.
2. Shovengerdt, R.A. (2013) *Distantsionnoye zondirovaniye. Modeli i metody obrabotki izobrazheniy*. M.: Tekhnosfera. 592 s.
3. Chao, K. (2002) Machine vision technology for agricultural applications. *Elsevier science transactions on computers and electronics in agriculture*. Vol. 36. P. 173-191.
4. Kumar, N. (2004) *Do leaf surface' characteristics affect agrobacterium infection in tea [camellia sinensis (1)]*. Vol. 29, № 3. P. 309-317.
5. Wu, L. (2009) Identification of weed, corn using BP network based on wavelet features and fractal dimension. *Scientific Research and Essay*. November, 2009. – Vol. 4 (11). – P. 1194-1400.
6. Qin, Zh. (2005) Detection of rice sheath blight for in-season disease management using multispectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*. Vol. 7. P. 115-148.

7. Aksoy, S. (2010) Automatic mapping of linear woody vegetation features in agricultural landscapes using very high-resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*. № 48 (1, 2). P. 511-522.
8. Abdullahi, H.S. (2017) Advances of image processing in Precision Agriculture: Using deep learning convolution neural network for soil nutrient classification. *Journal of Multidisciplinary Engineering Science and Technology (JMEST)*. Vol. 4, Issue 8. P. 7981-7987.
9. Wright, D., Rasmussen, V., Ramsey, R., Baker, D., Ellsworth, J. (2004) Canopy Reflectance Estimation of Wheat Nitrogen Content for Grain Protein Management. *GIScience Remote Sens.* Vol. 41, No. 4. P. 287-300.
10. Mate, K.A., Pooja, G., Kavita, S.R. (2016) Feature Extraction Algorithm for Estimation of Agriculture Acreage from Remote Sensing Images. P. 5-9.
11. Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Zhang, L. (2018) A fully convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery. *PLoS ONE* 13(4): e0196302.
12. Sa, I. (2018) WeedNet: Dense Semantic Weed Classification Using Multispectral Images and MAV for Smart Farming. *IEEE Robotics and Automation Letters*. Vol. 3(1). P. 588-595.
13. Potena, C., Nardi, D., Pretto, A. (2017) Fast and Accurate Crop and Weed Identification with Summarized Train Sets for Precision Agriculture: Intelligent Autonomous Systems. P. 105-121.
14. Yao, C., Zhang, Y., Zhang, Y., Liu, H. (2017) Application of convolutional neural network in classification of high resolution agricultural remote sensing images, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLII-2/W7. P. 989-992.
15. Atole, R.R., Park, D. (2018) A Multiclass Deep Convolutional Neural Network Classifier for Detection of Common Rice Plant Anomalies. *IJACSA: International Journal of Advanced Computer Science and Applications*. Vol. 9, No. 1. P. 67-70.
16. Rajmohan, R., Pajany, M., Rajesh, R., Raman, D.R., Prabu, U. (2018) Smart paddy crop disease identification and management using deep convolution neural network and SVM classifier. *International Journal of Pure and Applied Mathematics*. Vol. 118, No. 15. P. 255-264.
17. Athanikar, G., Badar, P. (2016) Potato Leaf Diseases Detection and Classification System. *International Journal of Computer Science and Mobile Computing*. Vol. 5 Issue, 2. P. 76-88.
18. Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., Stefanovic, D. (2016) Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*. 11 p.
19. Sobkowiak, B. (2006) Zastosowanie technik analizy obrazu do wczesnego wykrywania patogenow ziemniaka. Praca nie publicowana. Poznan: PIMR.
20. Sobkowiak, B. (2007) Zastosowanie technik analizy obrazu do wczesnego wykrywania zarazy ziemnechanej w warynkach polowych. Praca nie publicowana. Poznan: PIMR.
21. Nikolenko, S., Kadurin, A., Arkhangel'skaya, Ye. (2018) *Glubokoye obucheniye*. SPb.: Piter. 480 s.
22. Tensorflow API documentation. Available from: https://www.tensorflow.org/api_docs/python/tf/nn/softmax_cross_entropy_with_logits_v2

RESUME

V. Ganchenko, A. Doudkin

Convolutional neural networks in tasks of agricultural vegetation state monitoring on aerial images

A precision farming implies availability of accurate and promptly updated information about a state of vegetation and soil. It is only possible to obtain such information if remote sensing is used. Remote methods of monitoring agricultural fields allow quick identifying diseased areas of the vegetation in the early stages of development and cure the diseases promptly and with minimal cost. Artificial neural networks are commonly used for processing of aerial photographs of vegetation, particularly convolutional neural networks in application for weed out, classification of crops, classification of diseases and other tasks.

This article deals with recognition of vegetation areas, state of which has changed under diseases influence. The task under decision consists in the separation of images of agricultural fields into segments of three types (classes): soil, healthy vegetation, diseased vegetation. Origin data are aerial photographs of an experimental field of agricultural vegetation of various spatial resolutions. Analysis of color characteristics showed significant intersection of these characteristics for healthy and diseased vegetation. This fact significantly complicates identification and classification of image segments of the field. A presence different distortion on the field images (for instance, soil segments) also reduces classification accuracy: healthy areas may be recognized as diseased ones. At the same

time, vegetation and soil can be separated by color quite successfully.

To solve problem of classification into three classes, it is proposed to use a hierarchical classifier that consists of two-class classifiers "soil-vegetation" and "healthy vegetation-diseased vegetation." Each of them is a convolutional neural network with 33x33x3 inputs and an output layer with two neurons. The first convolutional neural network has two convolutional layers and one hidden fully connected layer and gives 96.9 % accuracy for "soil-vegetation" classification on validation set. The second classifier has four convolutional layers and two hidden fully connected layers. The accuracy for "healthy vegetation-diseased vegetation" classification is 93.8 % on validation set. For obtaining of three classes, the classification results are combined as follows: for "soil" class corresponding value of the first classifier is used; for "healthy vegetation" and "diseased vegetation", corresponding values of the second classifier are multiplied by value of output "vegetation" of the first classifier. Result accuracy for the classes is:

"diseased vegetation" – 74.29 %, "healthy vegetation" – 90.16%, and "soil" – 99.03 %. The classifier is implemented using Tensorflow library.

The use of convolutional neural networks allows reducing the influence of noise factors (lighting, sun glare) on the quality of maps of affected vegetation. At the same time, the proposed hierarchical classification reduces the distortion of the color characteristics of images of the neighborhoods of pixels when vegetation and a soil get into them.

Results obtained during the research will be further used for semantic image segmentation based on convolutional neural network.

Работа выполнена при поддержке БРФФИ (проект № Ф18В-005) и ГКНТ Республики Беларусь (проект № Ф18ПЛШГ-008П).

Надійшла до редакції 19.10.2018