

Разработка системы точечного внесения жидких средств химизации на основе моделей сверточной нейронной сети

Виктория Сергеевна Семенюк¹,
студент-магистр,
e-mail: viktoriya.semenyuk.98@mail.ru;

Евгений Александрович Никитин²,
аспирант, младший научный сотрудник,
e-mail: evgeniy.nicks@yandex.ru

¹Национальный исследовательский университет «Высшая школа экономики», Москва, Российская Федерация;

²Федеральный научный агроинженерный центр ВИМ, Москва, Российская Федерация

Реферат. Показали, что одна из причин потери урожая – некачественное определение степени пораженности сельскохозяйственных культур патогенами. Предложили систему точечного внесения жидких средств химизации. Выявили возможность расчета необходимого объема удобрений и средств защиты. (*Цель исследования*) Разработать систему точечного внесения жидких средств для защиты и питания растений на основе модели сверточной нейронной сети. (*Материалы и методы*) Провели анализ существующих архитектур и методов машинного обучения. При разработке системы использовали U-net-алгоритм сверточных нейронных сетей, а также данные, отображающие заболевания озимой и яровой пшеницы – бурую ржавчину и мучнистую росу. Каждое изображение кадрировали вручную и размечали с помощью специализированной Python-библиотеки. В ходе применения архитектуры экспериментальным путем выбрали оптимальные метрики (*jaccard metric*), скорость обучения – 0,0001 секунды, количество эпох – 300, а также другие показатели. (*Результаты и обсуждение*) Установили, что при подаче алгоритму нового, ранее не доступного изображения, он за несколько секунд распознает болезнь и возвращает пользователю не только исходное изображение, но и маску поверх него. Определили точность наложения маски на больной участок – 80 процентов. Показали, что прогнозируемая ошибка на валидационных данных составила 0,18758. На практике она может отличаться от заявленной не более чем на 10-15 процентов. Предложили использовать алгоритм с системой технического зрения. (*Выводы*) Показали, что несовершенство технических средств для химизации растений повышает расход до 30 процентов относительно объема, необходимого для точечного внесения. Разработали нейросетевой алгоритм для определения пораженных участков растений и предложили концепцию точечного внесения средств химизации растений с целью сокращения затраты при обработке посевов. Определили, что нейросеть способна диагностировать пораженные участки растений за 1 секунду.

Ключевые слова: точечное внесение удобрений, внесения средств защиты растений, сверточная нейронная сеть, машинное обучение, искусственный интеллект.

Для цитирования: Семенюк В.С., Никитин Е.А. Разработка системы точечного внесения средств химизации на основе модели сверточной нейронной сети // *Сельскохозяйственные машины и технологии*. 2021. Т. 15. №2. С. 41-45. DOI 10.22314/2073-7599-2021-15-2-41-45.

System Development for Liquid Chemicals Point Injection Based on Convolutional Neural Network Models

Victoria S. Semenyuk¹,
master's student,
e-mail: viktoriya.semenyuk.98@mail.ru;

Evgeniy A. Nikitin²,
postgraduate student, junior researcher,
e-mail: evgeniy.nicks@yandex.ru

¹National Research University Higher School of Economics, Moscow, Russian Federation;

²Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

Abstract. The authors showed that one of the reasons for the yield loss is poor-quality determination of the infection degree of agricultural crops by pathogens. They proposed a system of liquid chemicals point application. They identified the possibility of calculating the required amount of fertilizers and protective equipment. (*Research purpose*) To develop a system of liquid chemicals point application for plant protection and nutrition based on a convolutional neural network model. (*Materials and methods*) The authors analyzed the existing methods of machine learning. When developing the system, they used the U-net-algorithm of convolutional neural networks, as well as data displaying diseases of winter and spring wheat – brown rust and powdery mildew. Each image was cropped by hand and marked up using a specialized Python library. In the course of applying

the architecture, the authors experimentally chose the optimal metrics (jaccard metric), the learning rate – 0.0001 seconds, the number of epochs – 300, and other indicators. (*Results and discussion*) The authors found that when a new, previously unavailable image was submitted to the algorithm, it recognized the disease in a few seconds and returned to the user not only the original image, but also a mask over it. The accuracy of applying the mask to the affected area was determined – 80 percent. They showed that the predicted error on the validation data was 0.18758. In practice, it could differ from the declared one by no more than 10–15 percent. The authors suggested using the algorithm with a vision system. (*Conclusions*) The authors showed that technical means imperfection for plants chemicalization increased the consumption up to 30 percent relative to the volume required for point application. They developed a neural network algorithm for identifying the affected areas of plants and proposed the concept of a point chemicals application in order to reduce the costs of processing crops. It was determined that the neural network was able to diagnose the affected areas of plants in 1 second.

Keywords: point fertilization, plant protection products application, convolutional neural network, machine learning, artificial intelligence.

For citation: Semenyuk V.S., Nikitin E.A. Razrabotka sistemy tochechnogo vneseniya sredstv khimizatsii na osnove modeli svertochnoy neyronnoy seti [System development for liquid chemicals point injection based on convolutional neural network models]. *Sel'skokhozyaistvennyye mashiny i tekhnologii*. 2021. T. 15. N2. 41–45 (In Russian). DOI 10.22314/2073-7599-2021-15-2-41-45.

Потери урожая от вредителей и болезней, а также вследствие неблагоприятных климатических воздействий, сдерживают развитие растениеводства. Для снижения ущерба аграрии активно применяют химические средства защиты растений, внесение которых допустимо только при проведении предварительного обследования сельскохозяйственных угодий (согласно пункту 2.19 СанПиН 1.2.2584-10) [1]. Традиционно методика определения пораженности культур болезнями предусматривает большие затраты на работу агрономической службы. Немалая часть денежных средств расходуется на удобрения, внесение которых также зависит от степени поражения культур, спелости и других факторов [2, 3].

Российский и зарубежный опыт показал, что применение различных средств автоматизации технологических процессов растениеводства (систем параллельного вождения, дистанционного зондирования сельхозугодий, картирования посевных площадей) существенно повышает производительность труда и качество выполнения циклических операций [4, 5].

Уровень технологического развития систем технического зрения позволяет определять цветность и топологию объектов сканирования объектов с площадью анализа до 1 мм² [6, 7].

Метод диагностики заболеваний растений предусматривает использование системы технического зрения для определения оптимального количества химикатов (средств защиты растений и удобрений). Система опрыскивания на основе полученных данных помогает вносить их точно [8, 9]. Для потенциально здорового растения такие системы могут рассчитать объем внесения удобрений в зависимости от стадии созревания [10, 11].

В основе системы технического зрения заложен *U-net*-алгоритм сверточной нейронной сети. Он способен определять степень пораженности сельхозкультур и управлять каждой форсункой, установленной на

штанге опрыскивателя. Тем самым растение получает необходимое количество удобрений для дальнейшего роста или порцию средств защиты растений для уменьшения степени поражений [12–14].

Цель исследования – разработать систему точечного внесения жидких средств для защиты и питания растений на основе модели сверточной нейронной сети.

МАТЕРИАЛЫ И МЕТОДЫ. Изучили материалы международных выставок отрасли, сайты ведущих производителей современных технических, разработчиков технологических решений для растениеводства. Провели анализ существующих архитектур и методов машинного обучения.

Результаты и обсуждение. Большинство широкозахватных машин для внесения удобрений вносят одинаковое количество жидкости по всей обрабатываемой поверхности за один проход. Поэтому разработка предлагаемого метода внесения средств на основе сверточных нейронных сетей позволит существенно повысить технологическую эффективность и оптимизировать затраты на средства химизации растений и обеспечит их точечное внесение в соответствии со степенью поражения каждого микроучастка растения. Предложенный нами метод состоит в том, чтобы вносить жидкие средства соответственно степени распространения патогена.

Первой культурой для анализа стала пшеница как наиболее распространенная культура.

Для распознавания болезней на листьях выбрали архитектуру семантической сегментации изображений *U-net* (рис. 1). При ее использовании, в отличие от аналогов *E-net* и *FCN*, для получения результатов достаточно небольшого количества изображений. Такое преимущество возможно благодаря проведению аргументации (искажение исходного изображения по какому-либо паттерну).

U-net-архитектура состоит из сужающего пути




Рис. 1. Архитектура сверточных нейронных сетей U-net
Fig. 1. Convolutional neural networks U-net architecture

(слева) и расширяющего (справа). Она принимает размеченное изображение в разрешении 256×256 ($3 \times 256 \times 256$ image). На пути свертки изображение преобразуется в пиксели: используется свертка вниз (англ. *down convolution*) и уплотнение признаков (англ. *max pooling*), с которыми будет взаимодействовать компьютер для определения больного участка. На пути расширения архитектура разворачивает изображения (англ. *up convolution*) и производит процесс, обратный уплотнению (англ. *up sample*). В результате пользователю доступна маска поверх изображения ($k \times 256 \times 256$ masks).

Подготовка данных для сети включала кадрирование до размера 256×256 пикселей и разметку изображений. В соответствии с болезнями выделены два класса:

- мучнистая роса;
- бурая ржавчина.

Разметка изображений необходима для создания масок сверточной нейронной сети U-net (рис. 2).



Рис. 2. Разметка листа пшеницы, пораженного бурой ржавчиной
Fig. 2. Marking a wheat leaf affected by leaf rust

С помощью программного кода *json*-разметка изображений преобразована в маски формата *.jpg*, где синий цвет соответствует мучнистой росе, зеленый – бурой ржавчине (рис. 3).

При создании модели использовали следующие параметры:

- количество эпох – 300;
- скорость обучения нейронной сети 0.0001;
- размер батчей – 1;




Рис. 3. Маски болезней пшеницы
Fig. 3. Wheat disease masks

- метрики качества оценки сегментации – *jaccard metric*;
- число параллельно обрабатываемых изображений – 6;
- функция ошибки – ФокалЛосс (*FocalLoss*).

Метрику качества для оценки сегментации *jaccard metric* рассчитывают по формуле:

$$Jacc(A, B) = \frac{|A \cap B|}{|AB|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|},$$

где A – первое множество;

B – второе множество;

$A \cap B$ – пересечение множеств;

AB – объединение множеств.

При выборе функции ошибки рассмотрели несколько вариантов. Среди них самые успешные – *BinaryLoss* и *FocalLoss* с лучшими результатами на тестовой выборке 0,37324 и 0,00358 соответственно.

В процессе обучения модели выявляются ошибки на обучающих и валидационных данных (рис. 4).

Эпоха 1 Period 1	Эпоха 20 Period 20	Эпоха 150 Period 150	Эпоха 300 Period 300
loss = 0.05878 Valid loss: 0.08159	loss = 0.04056 Valid loss: 0.06113	loss = 0.02676 Valid loss: 0.04021	loss = 0.00358 Valid loss: 0.18758

Рис. 4. Значения ошибок при обучении модели в разных эпохах
Fig. 4. Errors values when training the model in different periods

Проходя каждую эпоху, модель становится более точной, отсекая шум (он становится черным) и отражая сверху маску. Параметр *loss* показывает ошибку при обучении на тестовых данных, *Valid loss* – на валидационных. Если применить модель к валидационным данным, то точность предсказания превысит 80%.

Рассмотрим результаты работы алгоритма. При обработке изображений он накладывает маску на картинку, выделяя синим цветом мучнистую росу и зеленым – бурую ржавчину (рис. 5). Для более точного про-




Рис. 5. Диагностика заболевания пшеницы с применением алгоритма U-net на примере мучнистой росы и бурой ржавчины: сверху – результат диагностики; внизу – исходное изображение
Fig. 5. Diagnosis of wheat disease with the U-net algorithm using powdery mildew and brown rust as an example: at the top – the diagnostic result; below is the original image

гноза рекомендуется использовать фотографии высокой точности, так как блики из-за характерного белого цвета и округлой формы могут быть ошибочно распознаны как мучнистая роса. Разработанный алгоритм определения заболевания растений с использованием системы технического зрения планируется задействовать в структуре технического средства (рис. 6).

Полученные данные о степени поражения растений, обрабатываемые блоком автоматического управления, могут послужить основой для управления множеством форсунок, установленных на штангу опрыскивателя. Изменяя напряжение и количество подаваемых импульсов, можно регулировать усилие запорной пружины и расход средств химизации.

Взаимодействие продемонстрированного алгоритма и структуры технических средств способствует решению ключевых проблем растениеводства:

- высокий расход средств защиты и удобрений при машинной обработке сельскохозяйств;
- неверное выявление и диагностирование болезней злаковых;
- ограниченный функционал отечественных машин по обработке растений средствами защиты.

Выводы. Проведенный анализ отрицательных факторов в растениеводстве показал, что несовершен-




Рис. 6. Система опрыскивания растений: 1 – энергетическое средство; 2 – емкость для средств химизации; 3 – блок автоматического управления; 4 – система технического зрения с TOF-камерой и камерой определения цветности растений; 5 – насос; 6 – штанга опрыскивателя с коллектором; 7 – множество выходных отверстий (определяется количеством форсунок и шириной обработки за один проход энергетического средства); 8 – форсунка; 9 – входной клапан форсунки; 10 – запорная пружина с регулируемым усилием; 11 – запорный конус форсунки; 12 – сопло; 13 – запорное кольцо; 14 – клапан обратного тока
Fig. 6. Plant spraying system: 1 – energy means; 2 – container for chemicals; 3 – automatic control unit; 4 – a technical vision system with a TOF camera and a camera for determining the plants color; 5 – pump; 6 – sprayer boom with a manifold; 7 – a plurality of outlet openings (determined by the nozzles number and the processing width in one pass of the power tool); 8 – nozzle; 9 – injector inlet valve; 10 – locking spring with adjustable force; 11 – nozzle shut-off cone; 12 – orifice; 13 – locking ring; 14 – reverse flow valve

ство технических средств для химизации растений повышает расход до 30% относительно объема, необходимого для точечного внесения.

Разработанный нейросетевой алгоритм для определения пораженных участков растений и предложенная концепция точечного внесения средств химизации растений позволит сократить затраты при обработке посевов. Эксперимент показал, что нейросеть способна диагностировать пораженные участки растений за 1 секунду.

Исследование проводится при поддержке Фонда содействия инновациям по договору № 524ГУЦЭС8-D3/61976 от 05.10.2020 года

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Лачуга Ю.Ф., Измайллов А.Ю., Лобачевский Я.П., Шогенов Ю.Х. Развитие интенсивных машинных технологий, роботизированной техники, эффективного энергообеспечения и цифровых систем в агропромышленном комплексе // *Техника и оборудование для села*. 2019. N6(264). С. 2-9.
2. Дорохов А.С., Новиков Н.Н., Митрофанов С.В. Интеллектуальная технология формирования системы удобрения // *Техника и оборудование для села*. 2020. N7 (277). С. 2-5.
3. Abubakar Auwal, Zin Hafiz M. Characterisation of Time-of-Flight (ToF) imaging system for application in monitoring deep inspiration breath-hold radiotherapy (DIBH-RT). *Biomedical physics & engineering express*. 2020.Vol. 6. Iss. 6. 065032.
4. Debrah D.A., Stewart G.A., Basnayake G. et al. Developing a camera-based 3D momentum imaging system capable of 1 Mhits/s. *Review of scientific instruments*. 2020. Vol. 91. Iss. 2. 023316.
5. Satorres M.S., Sanchez G.A., Estevez E.E. 3D object recognition for anthropomorphic robots performing tracking tasks. *International journal of advanced manufacturing technology*. 2020. Vol. 104. N1-4. 1403-1412.
6. Chen Y.C., Weng W.C., Lin S.W. A High Reliability 3D Object Tracking Method for Robot Teaching Application. 4th International Conference on Precision Machinery and Manufac-



turing Technology (ICPMMT). 2019. 012007.

7. Li F., Chen H., Pediredla A. CS-ToF: High-resolution compressive time-of-flight imaging. *Optics express*. 2017. Vol. 25. Iss. 25. 31096-31110.

8. Сибирев А.В., Дорохов А.С., Аксенов А.Г. Цифровизация машинной технологии уборки лука искусственными нейронными сетями // *Аграрная наука Евро-Северо-Востока*. 2019. Т. 20. №1. С. 84-91.

9. Сибирев А.В. Моделирование технологического процесса работы сельскохозяйственной машины искусственными нейронными сетями // *Вестник биотехнологии*. 2019. №1 (18). С. 6.

10. Watanabe S., Sumi K., Ise T. Identifying the vegetation type in Google Earth images using a convolutional neural network: a case study for Japanese bamboo forests. *BMC Ecology*. 2020. Vol. 20. Article 65.

11. Bagheri M., Al-Jabery K., Wunsch D., Burken J.G. Examining plant uptake and translocation of emerging contaminants using machine learning: Implications to food security. *Science of the total environment*. 2020. Vol. 698. Article 133999.

12. Younis S., Schmidt M., Weiland C., Dressler S., Seeger B., Hickler T. Detection and annotation of plant organs from digitised herbarium scans using deep learning. *Biodiversity data journal*. 2020. N8(10). Article e57090.

13. Семенюк В.С., Никитин Е.А. Основные направления государственной поддержки аграрного сектора экономики // *Наука без границ*. 2019. №1(29). С. 5-9.

14. Лобачевский Я.П., Ценч Ю.С., Бейлис В.М. Создание и развитие систем машин и технологий для комплексной механизации технологических процессов в растениеводстве // *История науки и техники*. 2019. №12. С. 46-55.

REFERENCES

1. Lachuga Yu.F., Izmaylov A.Yu., Lobachevskiy Ya.P., Shogenov Yu.Kh. Razvitie intensivnykh mashinnykh tekhnologiy, robotizirovannoy tekhniki, effektivnogo energoobespecheniya i tsifrovyykh sistem v agropromyshlennom komplekse [Development of intensive machine technologies, robotic technology, efficient energy supply and digital systems in the agro-industrial complex]. *Tekhnika i oborudovanie dlya sela*. 2019. №6(264). 2-9 (In Russian).

2. Dorokhov A.S., Novikov N.N., Mitrofanov S.V. Intellectuall'naya tekhnologiya formirovaniya sistemy udobreniya [Intelligent technology of forming a fertilizer system]. *Tekhnika i oborudovanie dlya sela*. 2020. №7(277). 2-5 (In Russian).

3. Abubakar Auwal, Zin Hafiz M. Characterisation of Time-of-Flight (ToF) imaging system for application in monitoring deep inspiration breath-hold radiotherapy (DIBH-RT). *Biomedical Physics & Engineering Express*. Vol. 6. Iss. 6, 2020. 065032 (In English).

4. Debrah Duke A., Stewart Gabriel A., Basnayake Gihan. Developing a camera-based 3D momentum imaging system capable of 1 Mhits/s. *Review Of Scientific Instruments*. Vol. 91. Iss. 2. 023316. 2020 (In English).

5. Satorres Martinez S., Sanchez Garcia A., Estevez Estevez E. 3D object recognition for anthropomorphic robots performing tracking tasks. *International Journal of Advanced Manufacturing Technology*. Vol. 104. №1-4. 2020. 1403-1412 (In English).

6. Chen Yan-Chun, Weng Wei-Chan, Lin Shi-Wei. A High Reliability 3D Object Tracking Method for Robot Teaching Application. 4th International Conference on Precision Machinery and Manufacturing Technology (ICPMMT). 2019.

7. Li Fengqiang, Chen Huaijin, Pediredla Adithya. CS-ToF: High-resolution compressive time-of-flight imaging. *Optics Express*. Vol. 25. Iss. 25. 2017. 31096-31110 (In English).

8. Sibiriyov A.V., Dorokhov A.S., Aksenov A.G. Tsifrovizatsiya

mashinnoy tekhnologii uborki luka iskusstvennymi neyronnymi setyami [Digitalization of machine technology for harvesting onions with artificial neural networks]. *Agrarnaya nauka Evro-Severo-Vostoka*. 2019. Vol. 20. №1. 84-91 (In Russian).

9. Sibiriyov A.V. Modelirovanie tekhnologicheskogo protsessa raboty sel'skhozayastvennoy mashiny iskusstvennymi neyronnymi setyami [Modeling the technological process of the agricultural machine with artificial neural networks]. *Vestnik biotekhnologii*. 2019. №1(18). 6 (In Russian).

10. Watanabe S., Sumi K., Ise T. Identifying the vegetation type in Google Earth images using a convolutional neural network: a case study for Japanese bamboo forests. *BMC Ecology*. 2020. Vol. 20. Article 65 (In English).

11. Bagheri M., Al-jabery K., Wunsch D., Burken J.G. Examining plant uptake and translocation of emerging contaminants using machine learning: Implications to food security. *Science of the total environment*. 2020. Vol. 698. Article 133999 (In English).

12. Younis S., Schmidt M., Weiland C., Dressler S., Seeger B., Hickler T. Detection and annotation of plant organs from digitised herbarium scans using deep learning. *Biodiversity Data Journal*. 2020. Vol. 8. Article e57090 (In English).

13. Semenyuk V.S., Nikitin E.A. Osnovnye napravleniya gosudarstvennoy podderzhki agrarnogo sektora ekonomiki [The main directions of state support for the agrarian sector of the economy]. *Nauka bez granits*. 2019. №1(29). 5-9 (In Russian).

14. Lobachevskiy Ya.P., Tsench Yu.S., Beylis V.M. Sozdanie i razvitie sistem mashin i tekhnologiy dlya kompleksnoy mekhanizatsii tekhnologicheskikh protsessov v rastenivodstve [Creation and development of systems of machines and technologies for complex mechanization of technological processes in crop production]. *Istoriya nauki i tekhniki*. 2019. №12. 46-55 (In Russian).

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

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

**Статья поступила в редакцию 25.01.2021
The paper was submitted
to the Editorial Office on 25.01.2021**

**Статья принята к публикации 07.04.2021
The paper was accepted
for publication on 07.04.2021**