

Сверточная нейронная сеть для оценки засоренности посевов гречихи

Риксен В.С.

Сибирский федеральный научный центр агrobiотехнологий РАН, Краснообск, Россия
Автор-корреспондент: riclog@mail.ru

Аннотация: Точная идентификация сорных растений в посевах сельскохозяйственных культур является важным шагом для системы защиты растений. С этой сложной задачей помогает справиться глубокое обучение, которое успешно развивается в течение последних 10 лет. В данной статье рассматривается построение модели сверточной нейронной сети с использованием архитектуры ResNet-18 для обнаружения и классификации 6 классов сорняков в посевах гречихи. Построенный классификатор имеет достаточно высокое качество предсказаний – 87 % и может быть использован для практических целей.

Ключевые слова: Сорные растения, сверточная нейронная сеть, классификатор, гречиха, ResNet-18.

Для цитирования: Риксен В.С. Сверточная нейронная сеть для оценки засоренности посевов гречихи. Умная цифровая экономика. 2023. Т.3, №1, с. 50-59

Convolutional neural network for assessing the weediness in buckwheat crops

Riksen V.S.

Siberian Federal Research Center of Agrobiotechnologies of the Russian Academy of Science, Krasnoobsk, Russia
Corresponding author: riclog@mail.ru

Abstract: Accurate identification of weeds in crops is an important step for a plant protection system. Deep learning, which has been successfully developing over the past 10 years, helps to cope with this difficult task. This article discusses the construction of a convolutional neural network model using the ResNet-18 architecture for the detection and classification of 6 classes of weeds in buckwheat crops. The constructed classifier has a fairly high quality of predictions - 87% and can be used for practical purposes.

Keywords: Weeds, convolutional neural network, classifier, buckwheat, ResNet-18.

For citation: Riksen V.S. Convolutional neural network for assessing the weediness in buckwheat crops. Smart Digital Economy. 2023. Vol.3, №1, pp. 50-59

Сорняки представляют серьезную проблему для производства сельскохозяйственных культур и препятствуют получению высоких урожаев. Повышение урожайности и

производства продуктов питания для растущего мирового населения является необходимым условием для решения проблем глобального голода (Walter et al., 2017; Caldera, Breyer, 2019).

Гречиха является важной продовольственной культурой. Получение низких урожаев в первую очередь связывают с низкой агротехникой (посев гречихи по плохим и засоренным предшественникам, слабую борьбу с сорняками до посева, недостаточное минеральное питание, потери зерна при уборке) (Fargoq et al., 2016; Дубенок и др., 2017).

Традиционные подходы к борьбе с сорняками могут стать более эффективными, если их интегрировать с моделями искусственного интеллекта (ИИ). Идентификация и классификация сорняков с применением методов ИИ могут сыграть важную роль в борьбе с сорняками, способствуя повышению урожайности (Potena et al., 2017; Bah et al., 2018; Zhang et al., 2018; Ahmed et al., 2019; Binguitcha-Fare et al., 2019).

Для демонстрации применения методов ИИ нами рассматривается задача построения классификатора, основанного на глубоком обучении Сверточной Нейронной Сети (СНС), способного к правильной идентификации сорняков и классификации степени интенсивности их присутствия на участках, занятых гречихой.

В качестве исходной информации для обучения СНС использовались наборы данных в виде фотографий (с разрешением 1440×1920), полученных с помощью мобильной фотокамеры и результатов фитосанитарной диагностики с 24 точек.

Мониторинг сорных растений был проведен в фазу бутонизации гречихи на 4 полях с помощью количественного метода учета засоренности поля (наложение рамки 0,25 м²). Количество площадок учета сорняков, согласно методике, зависело от размера поля. Согласно внутрихозяйственному обозначению рабочих участков, были обследованы поля О2/4 (фотоснимки Fig. 1-4), О9/2 (Fig. 5-8), О9/3 (Fig. 9-13), К8 (Fig. 14-24). На исследуемой территории хозяйства культуры возделываются по традиционной (классической – К8) и органической (О2/4, О9/2, О9/3) системе земледелия.

На участках с разной интенсивностью присутствовали такие сорные растения, как овсюг (*Avena fatua*), вьюнок полевой (*Convolvulus arvensis*) и просо куриное (*Echinochloa crus-galli*).

Задача классификатора состоит в распознавании этих сорняков на фотографии и определении одной из двух градаций засоренности ими участка - низкую или высокую. На полях с гречихой было определено 6 классов засоренности: *Avenafatua*0, *Avenafatua*1, *Convolvulusarvensis*0, *Convolvulusarvensis*1, *Echinochloacrus-galli*0, *Echinochloacrus-galli*1. Здесь идентификатор с 0 присвоен классу с засоренностью не превышающую ЭПВ, с 1 – превышающий ЭПВ.

На одной фотографии могут присутствовать как один сорняк с соответствующей градацией, так и несколько. Таким образом, задача построения искомого классификатора относится к задаче многокомпонентной классификации изображений по нескольким меткам.

Для выявления сорняков и их интенсивности мы использовали архитектуру ResNet-18, которая представляет собой хороший компромисс между затратами на вычисления, имеющимися в нашем распоряжении компьютеров и временем получения конечных результатов. Построение представленных в настоящей работе нейронных сетей основано на

применении предобученной сверточной нейросети (один из компонентов фреймворка PyTorch).

Архитектура ResNet-18 показана на рисунке 1. Имеются 4 сверточных блока, обозначенные на рисунке розовым, фиолетовым, желтым и оранжевым цветом. Каждый блок содержит 4 сверточных слоя. Вместе с первым сверточным слоем и последним полно связным слоем всего получается 18 слоёв. Поэтому эта модель широко известна как ResNet-18. Последний слой обозначен как avg pool, выход этого слоя сглаживается и подается на слой с функцией активации softmax, обозначенный как fc и выполняющего роль финального классификатора выходных классов. На схеме fc указан с максимальным возможным числом классов-1000.

В блоках, свертку на каждом слое производят фильтры размера 3x3, обозначенные как Conv, n, где n- число используемых фильтров, и если выходные карты признаков имеют одинаковый размер, то слои имеют равное число фильтров. Число фильтров удваиваются в слоях (обозначение - /2), в случае если выходная карта признаков уменьшена вдвое. Происходит понижение частоты дискретизации сверточных слоев с шагом 2.

В процессе обучения и тестирования, параметры, веса и смещения выбираются таким образом, чтобы минимизировать ошибку обучения, представляющую собой меру разности между фактическими и полученными на выходе сети признаками классов. В ResNet-18 в качестве такой меры используется бинарная перекрестная энтропия как функция потерь, а оптимизация параметров, весов и смещений сети осуществляется методом стохастического градиентного спуска.

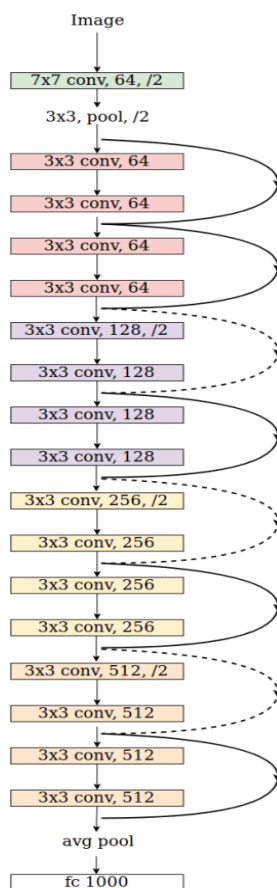


Рисунок 1 – Архитектура ResNet-18

Подытоживая, получаем следующую схему работы классификатора на базе модели ResNet-18: исходная фотография, проходит обработку через чередующиеся свёрточные слои, функции активации и pool-слои. В самом конце срабатывают правила финального классификатора, который показывает нам итоговые вероятностные оценки для каждого класса.

Поскольку в нашем распоряжении имеется сравнительно небольшое число изображений, что явно недостаточно для построения нейронной сети с хорошими обобщающими характеристиками, мы использовали прием увеличения объема исходных данных с помощью процедуры `aug_transforms`, встроенной в PyTorch. Применяемые в ней преобразования в виде вращения, масштабирования, перемещения и т. д., формируют разные изображения (из одних и тех же исходных образцов), создают вариации входных изображений, которые выглядят по-разному, но отображают одни и те же факты. Некоторые из этих преобразований носят случайный характер, например, кадрирование изображений, изменение яркости или контрастности. Дополнение этими изображениями исходного набора данных позволило увеличить их общий объем, используемый в модели нейросети в 6 раз.

Ожидаемый размер входных данных для нейронной сети ResNet-18, представленных в виде матрицы пикселей - 224×224 . Для того чтобы принимать входные данные снимков произвольного размера, в PyTorch предусмотрены соответствующие функции трансформации. Снимки с исходным пиксельным разрешением 1440×1920 сжимались до разрешения 512×512 с помощью процедуры `Resize`. Далее изображения масштабировались до требуемого входного формата.

Применяемая нами нейросеть была обучена с использованием тестового набора снимков, который использовался в алгоритме для получения более объективной и надежной модели. Перед началом обучения были установлены параметры модели, такие как количество эпох, размер партии, скорость обучения и т. д.

После определения первоначальных параметров, модель снова обучалась с оптимизатором Adam, который используется для достижения лучших результатов обучения. При обучении использовались различные эпохи: 10, 20, 30. Одна эпоха означает итерацию по всем используемым изображениям, которые последовательно вводятся для обучения партиями по 8 снимков. Общая точность выбранных моделей варьировалась от 77,5 до 90,8%. Полученные оценки приведены в таблице 1.

Таблица 1 – Результаты обучения нейросети по эпохам

Epoch	train_loss	valid_loss	accuracy_multi
1	0.860313	0.662197	0.483333
10	0.394793	0.395668	0.775000
20	0.264712	0.285602	0.858333

30	0.249835	0.266138	0.908333
.....			

В таблице 2 представлены основные параметры построенной нами нейросети на базе архитектуры ResNet-18. Размер вектора признаков для предпоследнего слоя conv5x составляет 25 088 (7×7×512) и 512 в случае слоя avg pool.

Размеры векторов признаков влияют на общий объем вычислений и время получения конечных результатов. Поскольку исходные цветные снимки сделаны с использованием стандартной цифровой камеры, то их цифровое представление на компьютере имеет 3 канала: красный, зеленый и синий, тогда как обычное серое изображение имеет только один канал.

Вывод ResNet-18 формируется в виде вектора размерности 6, где каждый компонент вектора дает оценку вероятности проявления соответствующего класса. Поскольку мы строим классификатор с несколькими метками, то у каждого изображения могут быть разные классы или вообще отсутствовать. Соответствующий класс предсказывается на изображении, если его вероятность выше 50%.

Таблица 2 – Основные структурные параметры нейронной сети ResNet-18 для Fagorugum

Имя слоев в блоках	Выходные размеры	Фильтры слоев
Conv1x	112 × 112 × 64	7 × 7, 64, шаг 2
Conv2x	56 × 56 × 64	3 × 3, 64 × 2 3 × 3, 64 × 2
Conv3x	28 × 28 × 128	3 × 3, 128 × 2 3 × 3, 128 × 2
Conv4x	14 × 14 × 256	3 × 3, 256 × 2 3 × 3, 256 × 2
Conv5x	7 × 7 × 512	3 × 3, 512 × 2 3 × 3, 512 × 2
avg pool	1 × 1 × 512	7×7, полно связный слой вектора признаков
fc	6	Классификатор с 512×6 соединениями

В следующей таблице представлены данные описывающие прогностические способности построенной нейросети, проверенные на исходной выборке. Выделенные красным цветом классы являются ошибочным прогнозом (табл. 3).

Таблица 3 – Сравнение соответствий между фактическими наблюдениями засоренности участка с Fagorugum и предсказаниями по классификатору

Снимки	Фактическая картина по сорнякам	Совпадения	Предсказание наличия сорняков по классификатору на базе ResNet-18
Fag 1.jpg	Avenafatua1	1	['Avenafatua1']
Fag 2.jpg	Avenafatua1	1	['Avenafatua1']
Fag 3.jpg	Echinochloacrus-galli1	1	['Echinochloacrus-galli1'],



Fag 4.jpg	Convolvularvensis1 Echinochloacrus-galli1	1	['Convolvularvensis1']
Fag 5.jpg	Convolvularvensis1 Avenafatua1	0,5	['Avenafatua0', 'Avenafatua1', 'Convolvularvensis0', 'Convolvularvensis1']
Fag 6.jpg	Avenafatua1	1	['Avenafatua1']
Fag 7.jpg	Convolvularvensis0 Avenafatua1	1	['Avenafatua1', 'Convolvularvensis0']
Fag 8.jpg	Avenafatua1	1	['Avenafatua1']
Fag 9.jpg	Convolvularvensis1 Avenafatua1	1	['Avenafatua1', 'Convolvularvensis1']
Fag 10.jpg	Convolvularvensis0 Avenafatua1	0,50	['Avenafatua1', 'Convolvularvensis1']
Fag 11.jpg	Convolvularvensis0 Avenafatua1	1	['Avenafatua1']
Fag 12.jpg	Avenafatua1 Echinochloacrus-galli0	1	['Avenafatua1', 'Echinochloacrus- galli0']
Fag 13.jpg	Convolvularvensis1 Avenafatua1	0,50	['Avenafatua1', 'Echinochloacrus- galli0']
Fag 14.jpg	Convolvularvensis1	0,50	['Avenafatua0', 'Convolvularvensis1']
Fag 15.jpg	Convolvularvensis1	0,50	['Avenafatua0', 'Convolvularvensis1']
Fag 16.jpg	Convolvularvensis1	1	['Convolvularvensis1']
Fag 17.jpg	Avenafatua1	1	['Avenafatua1'],
Fag 18.jpg	Convolvularvensis0 Avenafatua1	1	['Avenafatua1', 'Convolvularvensis0']
Fag 19.jpg	Convolvularvensis1	1	['Convolvularvensis1']
Fag 20.jpg	Convolvularvensis1	1	['Convolvularvensis1']
Fag 21.jpg	Convolvularvensis1	1	['Convolvularvensis1']
Fag 22.jpg	Convolvularvensis1	0,33	['Avenafatua0', 'Avenafatua1', 'Convolvularvensis1']
Fag 23.jpg	Convolvularvensis1 Avenafatua0	1	['Avenafatua0', 'Convolvularvensis1']
Fag 24.jpg	Convolvularvensis1	1	['Convolvularvensis1']

В таблице 4 приведены итоговые оценки прогностических способностей классификатора, полученные на исходном наборе данных из таблицы 3.

Таблица 4 – Итоговые оценки качества классификатора на основе ResNet-18

Общее число правильных классификаций для исходного набора 24 снимков	20,83
Правильные классификации в %	87
Абсолютно точные классификации в %	79

Полученные оценки говорят о достаточно высоком качестве классификатора и пригодности его применения для решения практических задач.

Еще одним показателем качества модели нейронной сети является Confusion matrix. Поскольку мы имеем дело с многокомпонентной классификацией, то построение матрицы проводится исходя из принципа «один против всех». С ее помощью можно определить с каким классом предсказания возникли проблемы.

На рисунке 2 приведены результаты построения Confusion matrix для каждой метки классов засоренности: 0-Avenafatua0, 1-Avenafatua1, 2-Convolvulusarvensis0, 3-Convolvulusarvensis1, 4-Echinochloacrus-galli0, 5-Echinochloacrus-galli1.

Строки каждой матрицы (размерности 2×2) представляют количество изображений с истинными метками: Y - соответствует числу изображений с выбранной меткой класса засоренности (образцы с истинной меткой данного класса), N - числу изображений всех остальных классов засоренности (все другие образцы с их истинными метками).

Столбцы представляют изображения, которые модель определила, как класс с выбранной меткой (столбец Y) и все остальные классы (столбец N).

Диагональ матрицы слева направо показывает изображения, которые были классифицированы верно (правильные прогнозы), вне диагонали отражается неверная классификация (неправильные прогнозы).






Рисунок 2 – Confusion matrix для классов засоренности, полученная по исходной выборке для участка с Fagopyrum

Классы с метками 1, 4, 5 были предсказаны наиболее точно, сумма неверно предсказанных и неверно не предсказанных классификаций равна 1. Для класса 2 и 3 сумма этих классификаций составила 3 и 2 соответственно. Наихудший результат прогноза для класса 0 – Avenafatua0. Возможно это связано с малочисленным количеством данного сорняка в тестовой выборке.

Согласно построенному классификатору для рабочего участка O2/4 спрогнозированы сорняки – овсюг, просо куриное, вьюнок полевой (в количестве превышающем ЭПВ), для участков O9/2, O9/3, K8 – овсюг и вьюнок полевой. Поскольку гречиха на полях O2/4, O9/2, O9/3, возделывается по органической системе земледелия, в таких полевых севооборотах оптимизация фитосанитарного состояния посевов базируется, прежде всего, на комплексе организационно-хозяйственных и агротехнических мероприятий, использовании механических и физических методов защиты растений. Прежде всего необходима своевременная и высококачественная подготовка почвы, использование устойчивых сортов и гибридов, разработка специальных севооборотов, пространственная изоляция посевов, применение микробиологических препаратов при превышении экономических порогов вредоносности вредителей, болезней и сорняков. Что же касается участка K8, который возделывается по традиционной системе земледелия, наиболее эффективным методом борьбы против корнеотпрысковых, корневищных сорняков и однолетних однодольных злаковых сорняков в фазу бутонизации гречихи будет гербицидная обработка (на основе таких действующих веществ, как Феноксапроп-П-этил, Клетодим + галоксифоп-Р- метил и др.). Для

предупреждения путей распространения сорняков и ликвидации очагов сорной растительности необходимо соблюдать регламент всех технологических мероприятий в процессе выращивания сельскохозяйственных культур.

В результате исследования построен классификатор на базе модели глубокого обучения ResNet-18, который с высокой точностью способен распознавать сорняки с соответствующими грациями засоренности на фотоснимках с полей гречихи. Несомненным преимуществом нашего подхода к построению сверточной нейронной сети можно отнести высокую точность входных данных, полученных специалистами при фитосанитарной диагностике посевов. Предлагаемый метод очень гибкий, поскольку модель может продолжить обучаться на новом наборе данных, в следствии чего становится более универсальной и точной. Метод, представленный в данной статье, станет важным шагом на пути к точному земледелию для решения такой сложной задачи, как идентификация сорных растений в посевах сельскохозяйственных культур.

Список литературы

1. Ahmed F., Bari A. H., Hossain E., Al-Mamun H. A., Kwan P. Performance Analysis of Support Vector Machine and Bayesian Classifier for Crop and Weed Classification from Digital Images // World Applied Sciences Journal – 2019. – Т. 12– №. 4. – С. 432-440.
2. Bah M. D., Hafiane A., Canals R. Deep learning with unsupervised data labeling for weed detection in line crops in UAV images // Remote sensing. – 2018. – Т. 10. – №. 11. – С. 1690. doi: 10.3390/rs10111690
3. Binguitcha-Fare A. A., and Sharma, P. Crops and weeds classification using Convolutional Neural Networks via optimization of transfer learning parameters // International Journal of Engineering and Advanced Technology (IJEAT) – 2019. – Т. 8 – №. 5. – С. 2285-2294.
4. Caldera U., Breyer C. Assessing the potential for renewable energy powered desalination for the global irrigation sector // Science of the Total Environment. – 2019. – Т. 694. – С. 133598. doi: 10.1016/j.scitotenv.2019.133598
5. Farooq S., Rehman R. U., Pirzadah T. B., Malik B., Dar F. A., Tahir I. Cultivation, agronomic practices, and growth performance of buckwheat // Molecular breeding and nutritional aspects of buckwheat. – Academic Press, 2016. – С. 299-319. doi: 10.1016/B978-0-12-803692-1.00023-7
6. Potena C., Nardi D., Pretto A. Fast and accurate crop and weed identification with summarized train sets for precision agriculture // Intelligent Autonomous Systems 14: Proceedings of the 14th International Conference IAS-14 14. – Springer International Publishing, 2017. – С. 105-121. doi: 10.1007/978-3-319-48036-7_9
7. Walter A., Finger R., Huber R., Buchmann N. Smart farming is key to developing sustainable agriculture // Proceedings of the National Academy of Sciences. – 2017. – Т. 114. – №. 24. – С. 6148-6150. doi: 10.1073/pnas.170746211
8. Zhang W., Hansen M.F., Volonakis T.N., Smith M., Smith L., Wilson J., Ralston G., Broadbent L., Wright G. Broad-leaf weed detection in pasture // IEEE 3rd International Conference on Image, Vision and Computing. – 2018. – С. 15-23



9. Дубенок Н. Н., Заяц О. А., Стрижакова Е. А. Формирование продукционного потенциала гречихи (*Fagopyrum esculentum* L.) в зависимости от уровня минерального питания и способа посева // Известия Тимирязевской сельскохозяйственной академии. – 2017. – № 6. – С. 29-41. – DOI 10.26897/0021-342X-2017-6-29-41. – EDN YOKBLU.