

УДК 620.164.1

АЛГОРИТМЫ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ПРИКЛАДНЫХ ЗАДАЧ

Сабитов Б.Р., Алмазбеков Э.А., Таштанкулова А.Ж.

Кыргызский технический университет им. И. Раззакова

В данной работе исследуются различные архитектуры сверточных нейронных сетей. Сверточные нейронные сети – это, яркий представитель типичной глубокой нейронной сети. Структура глубокого обучения в основном называется нейронной сетью, который обрабатывается со скрытыми слоями для улучшения обучения.

Ключевые слова: сверточные нейронные сети, глубокое обучение, распознавания листьев растений

КОЛДОНУЛГАН МАСЕЛЕЛЕРГЕ ПРОГНОЗДОО ҮЧҮН ТЕРЕҢ ҮЙРӨНҮҮ АЛГОРИТМДАРЫ

Сабитов Б.Р., Алмазбеков Э.А., Таштанкулова А.Ж.

И.Раззаков атындагы Кыргыз техникалык университети

Бул макалада ар кандай конволюциялык нейрон тармактарынын архитектурасы каралат. Convolutional нейрон тармактары типтүү терең нейрон тармагынын негизги мисалы болуп саналат. Терең окутуу структурасы, адатта, окутууну жакшыртуу үчүн жашыруун катмарлар менен иштетилген нейрондук тармак деп аталат.

Баштапкы сөздөр: конволюциялык нейрон тармактары, терең үйрөнүү, өсүмдүк жалбырактарын таануу

DEEP LEARNING ALGORITHMS FOR FORECASTING APPLIED PROBLEMS

Sabitov B.R., Almazbekov E.A., Tashtankulova A.Zh.
Kyrgyz Technical University named of I. Razzakov

This paper examines various convolutional neural network architectures. Convolutional neural networks are a prime example of a typical deep neural network. A deep learning structure is typically called a neural network, which is processed with hidden layers to improve learning.

Keywords: convolutional neural networks, deep learning, plant leaf recognition

Введение. Техника CNN в основном используется в глубоком обучении для обработки изображений, например листьев растений. В сверточной нейронной сети изображения анализируются попиксельно в матричном формате, затем формируется фильтр, который был назван сверткой. В данной работе для широкого класса задач было использовано сверточная основа нейронных сетей. Сверточные нейронные сети имеют большие практические применения для распознавания изображений. На Рис.4.1, приведены множества прикладных задач сельского хозяйства, где CNN играет существенную роль.

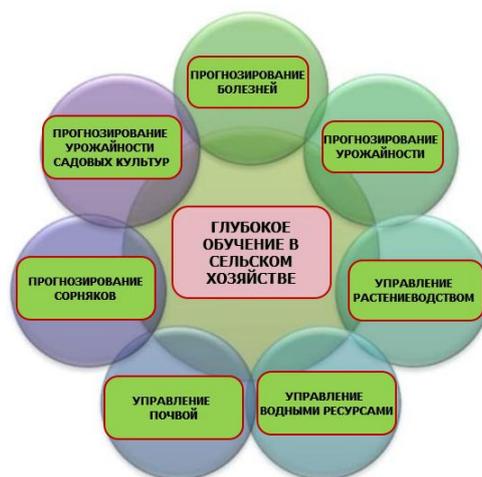


Рис.1. Практическое применение для приложений CNN в глубоком обучении для задач сельского хозяйства.

Глубокое обучение имеет важную роль как современный инструмент при исследовании идентификации и выявлении болезней растений, которые в условиях изменения климата является сложной

задачей сельского хозяйства. Заболевания растений можно определить с помощью метода глубокого обучения, с помощью сверточных нейронных сетей (CNN), в котором изображения это зараженные листья болезнью.

С применением CNN и базы данных больных и здоровых листьев растений в работе исследованы 25 видов сельскохозяйственных растений, находившихся на разных стадиях вегетации. С использованием изображений в количестве около 80 000 больных листьев растений, обучены модели, которые дают четкое представление о конкретном растении и выдает желаемое правильный результат о болезни растений. Сверточная нейронная сеть (CNN) играет важную роль, когда она определяет точное положение пораженной части, что помогает поставить высокоточный диагноз. Заболевания растений также можно остановить до ее возникновения, если удастся выявить факторы, вызывающие заболевания. Как правило, существуют факторы, влияющие на растения климат и внешние факторы, такие как насекомые. Для аграриев было бы полезнее, если заболевания были выявлены в момент воздействия внешних факторов, вызывающих повреждение. Грибок, бактериальные инфекции обычно вызваны климатическими изменениями и периодическими появлениями вредителей и насекомых.

Методы исследования. Глубокое обучение с сверточными нейронными сетями помогает идентифицировать различные части листьев больных растений и вредителей, лежащих на нем. Это помогает фермерам, чтобы обнаружить болезнь растений быстро и уменьшить ущерб урожаю.

Для строгого математического определения свертки мы обсудим теоретические концепции, необходимые для ее изучения и нейронных сетей.

Сверточные нейронные сети основаны на свертках. Математически свертка определяется как функция, она также может быть определена как оператор от $L^p(R)$ к самому себе для $1 \leq p \leq 2$, где $T_\omega(f) = f * \omega$ для некоторого $\omega \in L^1(R)$. Обычно CNN использует свертку в своих сверточных слоях. Определяя нейронную сеть как композицию карт слоев, мы обнаруживаем, что нейронная сеть по необходимости и является пространством Липшица. В то время как CNN могут быть очень мощными инструментами для классификации изображений, однако незначительные изменения в изображении могут полностью нарушить устойчивость нейронной сети.

Определим ряд свойств свертки как в дискретном, так и в непрерывном случаях. Начнем с классического определения:

Определение 4.1. Для $f, \omega \in L^1(\mathbb{R})$, мы определяем свертку f и ω как

$$(f * \omega)(x) = \int f(y)\omega(x - y)dy, y \in \mathbb{R} \quad (1)$$

В терминологии сверточных сетей первый аргумент f , называется входом, а второй ω - ядром. Выход обычно называют картой признаков. Если мы предположим, что f и ω определены только для целых x , тогда мы получим определение дискретной свертки.

$$(f * \omega) = \sum_{i=-\infty}^{\infty} f(y)\omega(x - y), \quad (2)$$

В приложениях машинного обучения входом обычно является многомерный массив данных, а ее ядром является многомерный массив параметров, которые адаптированы алгоритмом обучения. На практике сумму в (4.2) от минус до плюс бесконечности заменяют конечными числами. Вообще если входом является двумерное изображение I , то и ядро должно быть двумерным:

$$S(i, j) = (I * K)(i, j) = \sum_n \sum_m I(m, n)K(i - m, j - n) \quad (3)$$

Операция свертки является коммутативным, поэтому формулу (4.3.) можно записать виде:

$$S(i, j) = (K * I)(i, j) = \sum_n \sum_m I(i - m, j - n)K(m, n), \quad (4)$$

Обычно вторую формулу (4.4) проще реализовать в библиотеках машинного обучения. Ниже показаны результаты применения свертки применительно к задачам распознавания листьев растений.

Здоровые листья



Рис.2. Изображения здоровых листьев после применения операции свертки.

Листья покрытые шероховатостью и скрученностью

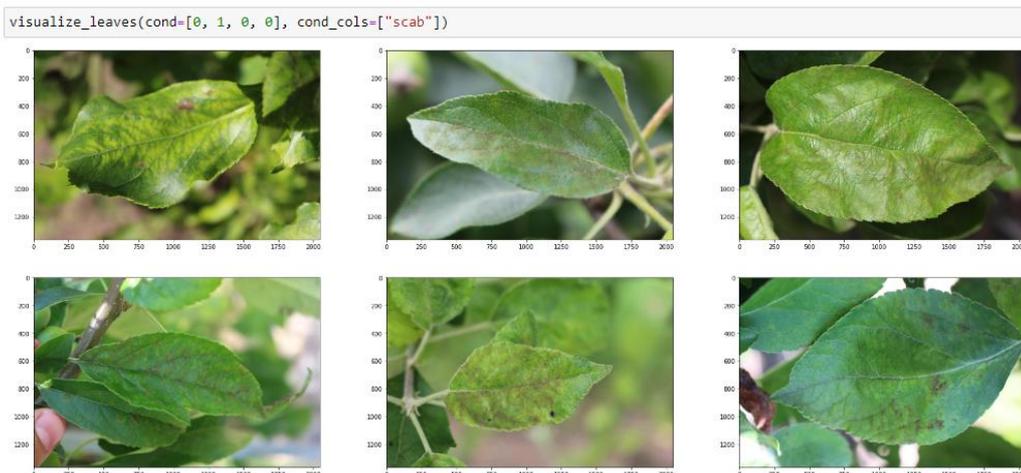


Рис.3. Изображения больных листьев после применения операции свертки.

В приложениях, часто иногда полезно использовать функцию перекрестной корреляции, та же свертка только без отражения ядра.

$$S(i, j) = (I * K)(i, j) = \sum_n \sum_m I(i + m, j + n)K(m, n), \quad (5)$$

Результаты и обсуждения. Рассматриваются полученные результаты по моделированию в глубоком обучении. Получены результаты в настоящей работе основаны на архитектурах сверточных нейронных сетей, как Resnet50, VGG16, InceptionV3, MobileNetV2, VGG19, AlexNet и EfficientNet, которые были использованы для построения моделей для прогнозирования болезней груш. Следует отметить, что использование трансферного -предварительного, обучения модели на наборе данных, связанных с растениями, с большим количеством изображений и классов (крупномасштабный), а также с широким разнообразием изображений ImageNet является необходимым условием для построения успешной-требуемой модели. Следовательно, поиск подходящего исходного набора данных, для построения улучшенных моделей имеет важное значение для распознавания болезней растений.

В работе исследован технологии трансферного обучению с использованием четырех предварительно обученных архитектур CNN, включая Xception, ResNet50, EfficientNetB4 и MobileNet-V2, был принят для обнаружения ржавчины на грушах. При трансферном обучении модель может использовать ранее полученные знания из других задач для решения новой проблемы. Поскольку при трансферном обучении модели предварительно уже обучаются на большом наборе данных, по сравнению с обучением модели с нуля требуется меньше данных, а

также это может сэкономить время обучения и повысить производительность модели. Ниже полученные оценки показывают, что предлагаемые методы трансферного обучения с технологиями глубокого обучения могут улучшить общую производительность классификации болезней груши. При использовании технологий распознавания на Pytorch результаты показали на 93.94% на обучающем множестве данных и 79.79% на данных валидации. На обновленной базе данных Plant Village прогнозирование болезни груш составил Train Accuracy: 0.97504325, Test Accuracy:0.9362568, Validation Accuracy: 0.94163530.Ниже на рисунках приведены результаты реализации нейронных сверточных сетей ResNet, VGG16, Inception, CNN и Alex Net и EfficientNetV2S с помощью трансферного обучения.

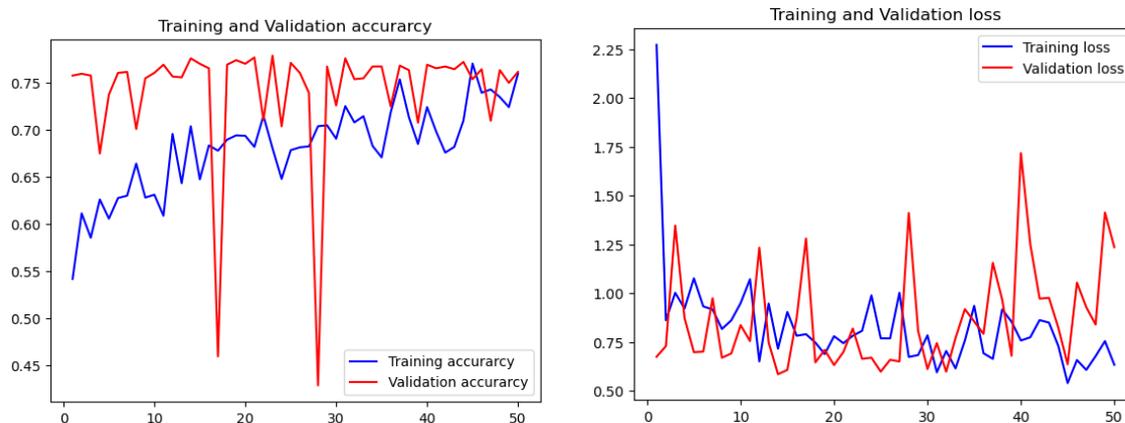


Рис. 4. Трансферное обучение на основе модели Resnet50. Показатели ResNet следующие: Validation_loss: 0.5299 – Validation_accuracy: 0.7761

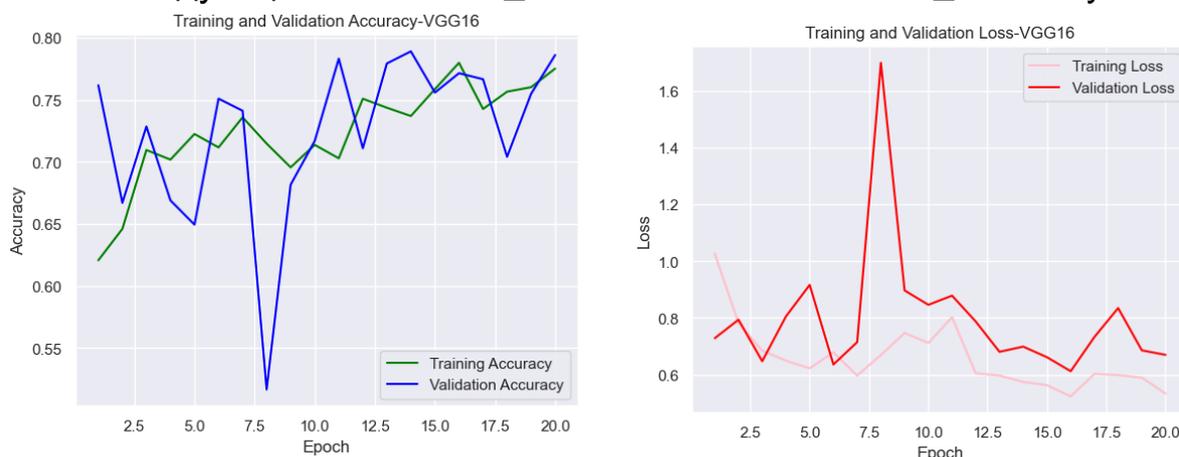


Рис. 5. Трансферное обучение на основе модели VGG-16.

Результаты трансферного обучения VGG116, следующие: validation_loss: 0.6699 – validation_accuracy: 0.7861. Аналогичные сети Inception, MobileNet представляет собой сверточную архитектуру, созданную для достижения высоких результатов за счет снижения вычислительной сложности, необходимой для сверточных слоев.

Заключение

Основная цель работы была направлена на реализацию модели глубокого обучения, которые могут эффективно прогнозировать прикладные задачи. Получены следующие результаты.

- Сфокусировано на раннем обнаружении качества воздуха, что имеет решающее значение для охраны общественного здоровья и окружающей среды, с потенциалом спасти миллионы жизней во всем мире.
- Разработано передовая система прогнозирования прикладных задач, которая объединяет различные методы машинного обучения, включая регрессионной модели, случайный лес, опорную векторную машину, дерево решений, достигая замечательной высокой точности классификации как с моделями случайного леса, так и дерева решений.
- Построены нейронная сеть для прогнозирования конкретных задач
- Проведен сравнительный анализ нейронного и машинного моделирования прикладных задач
- Для большого круга задач в растениеводстве использовано трансферное обучение

ЛИТЕРАТУРА

1. Сабитов, Б.Р. Идентификация болезней томатов на основе многоклассовой классификации. [Электронный ресурс] / Б.Р.Сабитов, Н.С.Сейткадиева, А.Дж. Картанова// Проблемы автоматизации и управления 2022. - № 3(45). – С.11.-Режим доступа: <https://www.elibrary.ru/item.asp?id=50020292>. – Загл.с экрана.
2. Сабитов, Б.Р. Моделирование и прогнозирование задач сельского хозяйства на основе машинного обучения [Электронный ресурс] / Б.Р.Сабитов // Тр.Межд. научно-практ.конф. Научно-технологическое развитие АПК для целей устойчивого развития. – Режим доступа: <https://www.conferences.org/articles/e3sconf/abs/2023/17/contents/contents.html>. – Загл.с экрана.
3. Sabitov, B.R. Deep learning Methods for Recognition of Orchard Crops [Электронный ресурс] / B.R. Sabitov, S.Biibsunova, A.Kashkaroeva et al. // IJCSNS. – 2022. – Vol.22. – No.10. – Режим доступа: http://paper.ijcsns.org/07_book/202210/20221033.pdf. – Загл.с экрана.
4. Pu, Y. Variational autoencoder for deep learning of images, labels and captions [EB/OL] [Text] / Y. Pu, Z. Gan, R.Henano et al. // 2016. – 09.28. – arxiv. – No.1609.08976.