

## Особенности реализации интеллектуальной модели по распознаванию болезней яблонь по листьям

*З.Х. Калажоков*

*Финансовый университет при Правительстве Российской Федерации, Москва*

**Аннотация:** В данной статье рассматриваются особенности реализации модели для распознавания болезней яблонь по листьям. В ходе работы проведен ряд экспериментов с известными архитектурами сверточных сетей (ResNet50, VGG16 и MobileNet), рассматривается влияние на точность изменение параметров сети - количества слоев, пакетная нормализация. Приводится описание практического опыта построения своей сети классификации болезней и решение проблем, возникающих при обучении. В частности, показано, что пакетная нормализация или углубление сети могут положительно сказываться на таком эффекте, как затухание градиентов. Для наглядности в работе приведены графики обучения нейронных сетей. В процессе работы сформированы выводы и рекомендации.

**Ключевые слова:** искусственный интеллект, компьютерное зрение, нейронные сети, глубокое обучение, машинное обучение.

### Введение

Болезни растений оказывают серьезное влияние на урожайность и качество сельскохозяйственных культур, а также снижают экономические доходы фермеров. Однако, диагностика заболеваний растений с использованием классических методов не всегда позволяет определить тип заболевания вовремя, что приводит к возникновению более серьезных проблем. Поэтому активно ведутся исследования в области выявления болезней сельскохозяйственных культур по симптомам болезней на листьях. Раннее обнаружение и идентификация болезней на ранних стадиях являются ключевыми для успешного лечения. Однако, фермеры часто сталкиваются с трудностями в обнаружении заболеваний, что может привести к упущению возможности борьбы с болезнью. Каждая болезнь требует своего подхода к лечению. Например, возможно предотвратить грибковые заболевания путем своевременного нарушения жизненного цикла возбудителя. В настоящее время методы выявления болезней растений являются ручными, основываясь на справочниках или опыте фермеров.

---

В данной статье целью является освещение опыта реализации модели диагностики болезней листьев яблони и классификация по типу болезни, показать какие сложности могут возникнуть в процессе разработки и пути их решения.

В литературе существует ряд работ по этой теме, например в [1] приводится опыт реализации классификатора - предложена многослойная сверточная нейронная сеть (MCNN), которая способна классифицировать листья яблони по одной из следующих категорий: парша яблони, черная гниль и болезни яблоневого кедровой ржавчины. Авторы использовали методы аффинного и перспективного преобразования для увеличения размера набора данных. После этого применялись операции предварительной обработки на основе метода кадрирования и выравнивания гистограммы.

В [2] авторы предложили модель новой сверточной нейронной сети RegNet. Была проведена серия сравнительных экспериментов на основе 2141 изображения 5 болезней листьев яблони (ржавчина, парша, кольцевая гниль, панонихус ульми и здоровые листья) в полевых условиях. Результаты показывают, что RegNet-Adam со скоростью обучения 0,0001 получила среднюю точность 99,8% на проверочном наборе и общую точность 99,23% на тестовом наборе

В [3] авторы предложили новую модель идентификации на основе улучшения архитектуры ResNet-50, которая дополнительно включает модуль внимания к координатам (CA) и адаптивное к весу многомасштабное слияние признаков (WAMFF) для улучшения возможностей извлечения признаков изображения ResNet-50. Для повышения обобщающей способности модели используются трансферное обучение и улучшение онлайн-данных. Предложенная модель достигла 1-го уровня точности 98,32% на основе наборов данных AppleLeaf9.

---

Для обнаружения болезней сельскохозяйственных культур широко используются такие популярные методы, как искусственная нейронная сеть (ANN), алгоритм К ближайших соседей (KNN) и другие алгоритмы. Наиболее часто яблони поражаются несколькими болезнями, основными из которых являются парша яблони (*Venturia inaequalis*), черная гниль яблони (*Botryosphaeria obtusa*) и кедровая ржавчина яблони (*Gymnosporangium juniperi-virginianae*).

### Основная часть

Модели глубокого обучения строятся на наборах данных. Для данной работы был произведен поиск подходящих наборов данных и было найдено несколько датасетов, из которых был выбран один наиболее подходящий [4]. Из этого датасета были выбраны 4 категории листьев: черная гниль, кедровая ржавчина, парша яблони и здоровые листья, всего 2226 фотографий, разделенных по папкам на 4 класса.

Фотографии предварительно были разбиты на тренировочную, тестовую и валидационную выборки, в процессе обработки подверглись обработке в плане изменения размера до 255x255 px, и аугментации путем отображения по вертикали и горизонтали, поворота на случайные углы.

Было проведено несколько серий экспериментов, в каждой из которых строилась модель и исследовалась в зависимости от изменения параметров сети.

В первой серии экспериментов применялся метод обучения с переносом (Transfer Learning), были построены модели для известных хорошо себя зарекомендовавших сетей ResNet50, VGG16 и MobileNet, которые входят в состав библиотеки Keras. При этом для кривых при тренировке и валидации переобучения не наблюдалось. На рис.1 и на рис.2 приведены группы кривых для валидационной выборки.

---

Для отображения результатов применялся TensorBoard. Кривые были искажены помехами, поэтому применялось сглаживание кривых - замена фактических значений потерь и точности их экспоненциальным скользящим средним. В всех экспериментах для соблюдения единообразия устанавливалось сглаживание в 0,907.

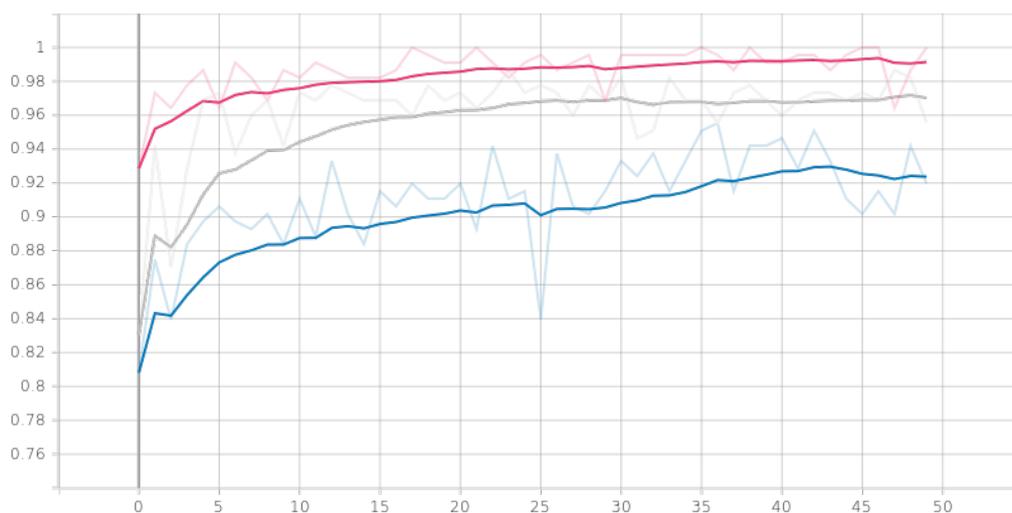


Рис. 1. – Кривые точности для валидационной выборки для предобученных сетей ResNet50, VGG16 и MobileNet

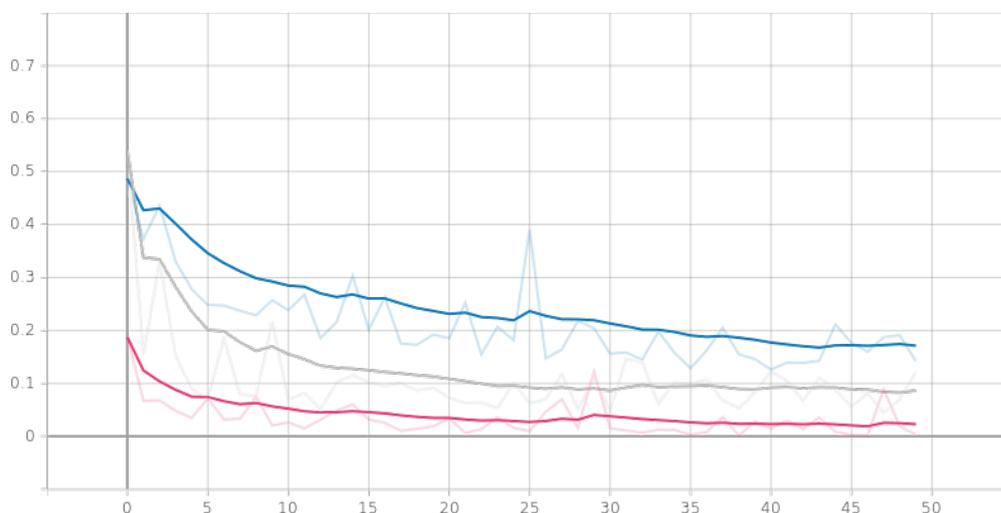


Рис. 2. – Кривые потерь для валидационной выборки для предобученных сетей ResNet50, VGG16 и MobileNet

Наблюдается снижение точности модели для кривых ResNet50, VGG16 и MobileNet соответственно.

Далее была выбрана сеть VGG16, которая обучалась и тестировалась при 7 разных значениях процента размороженных обучаемых слоев от 10 до 80 процентов. Также применялась ранняя остановка обучения, если значения точности не меняются выше заданного порога более 10 эпох. В результате проведенных экспериментов какой-либо закономерности установить не удалось, хотя были ожидания, что с увеличением процента размороженных слоев точность должна расти.

Была написана самописная сеть с несколькими скрытыми слоями, которая также обучалась и тестировалась на том же наборе данных при различных количествах скрытых слоев.. Результаты этой серии экспериментов представлены на рис.3 и рис.4.

При этом для кривых при тренировке и валидации заметного переобучения также не наблюдалось.

В результате этой серии экспериментов можно сделать следующие выводы. При меньшем количестве скрытых слоев обучение на начальных этапах проходит наиболее активно, но начиная примерно с 25 эпохи кривые сетей с 3 и 4 слоями догоняют их и превосходят, хоть и незначительно на конечной 50 эпохе. Если добавлять слоя больше 4, то обучаемость модели заметно ухудшается, как и точность на 50 эпохе. Кривая с 5 слоями показывает отставание как в точности, так и в обучаемости. Можно предположить, что такое поведение модели объясняется эффектом затухающих градиентов, который проявляет себя в том, что слои, которые отстоят на большем расстоянии от выходного слоя обучаются хуже, чем слои, находящиеся ближе к выходу модели. Это известный эффект и в литературе [5,6] объясняется тем, что параметры слоя, находящегося ближе к выходному слою, имеют более прямую связь со стоимостью, чем дальше слой от выходного, тем запутанней становится связь между его параметрами и стоимостью. В результате в направлении от выхода сети к его входу

---

наблюдается выравнивание градиента данного параметра по стоимости, он постепенно исчезает. Есть способы устранения влияния этого эффекта. Один из них - это уменьшение количества слоев, что уже очевидно по кривым на рисунке, но в этом случае также ухудшается точность модели. Другой способ - это использование функции активации  $\tanh$ , но это не дало результатов.

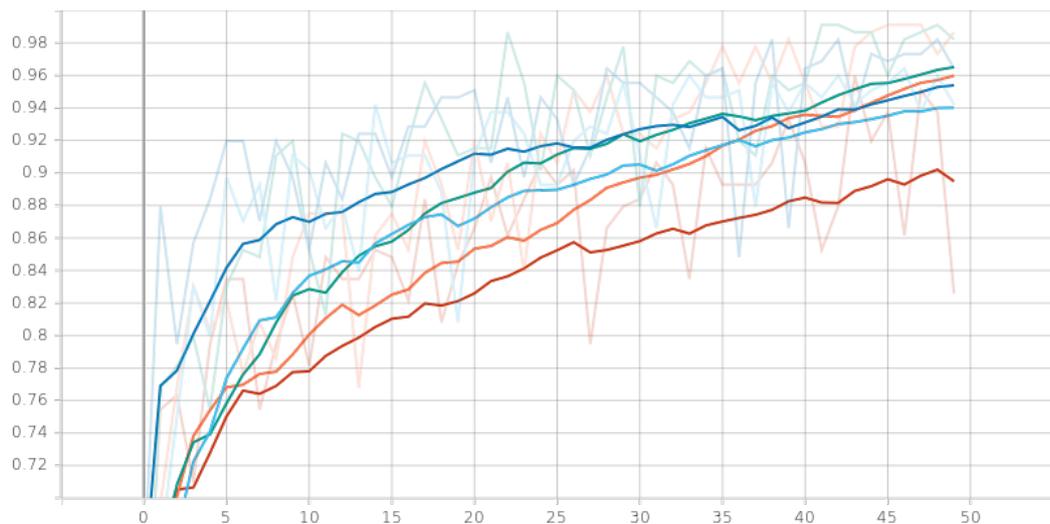


Рис. 3. – Кривые точности для валидационной выборки для самописной сети при разном количестве скрытых слоев.

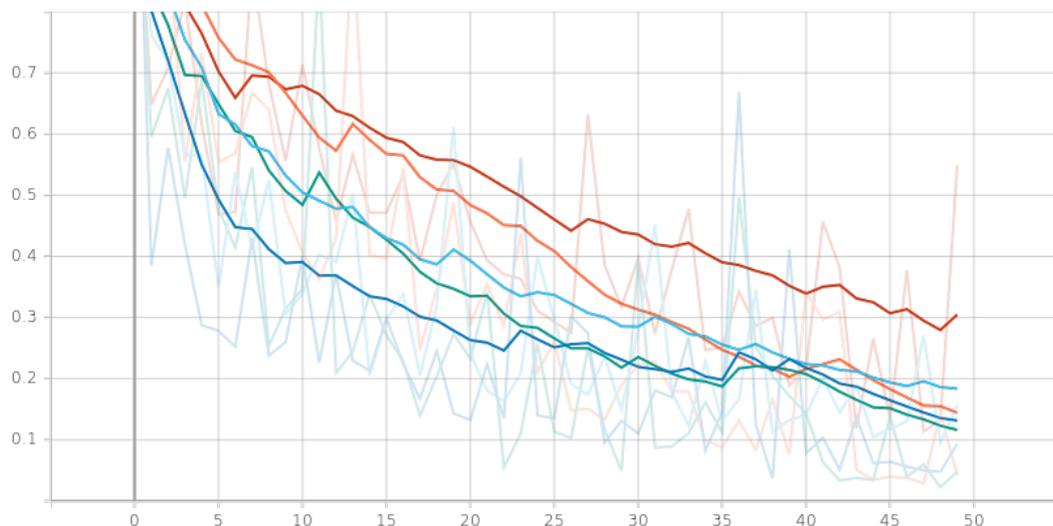


Рис. 3. – Кривые потерь для валидационной выборки для самописной сети при разном количестве скрытых слоев.

Был применен другой способ - пакетная нормализация [5,6].

На рис. 5 и рис. 6 показаны кривые точности при пакетной нормализации.

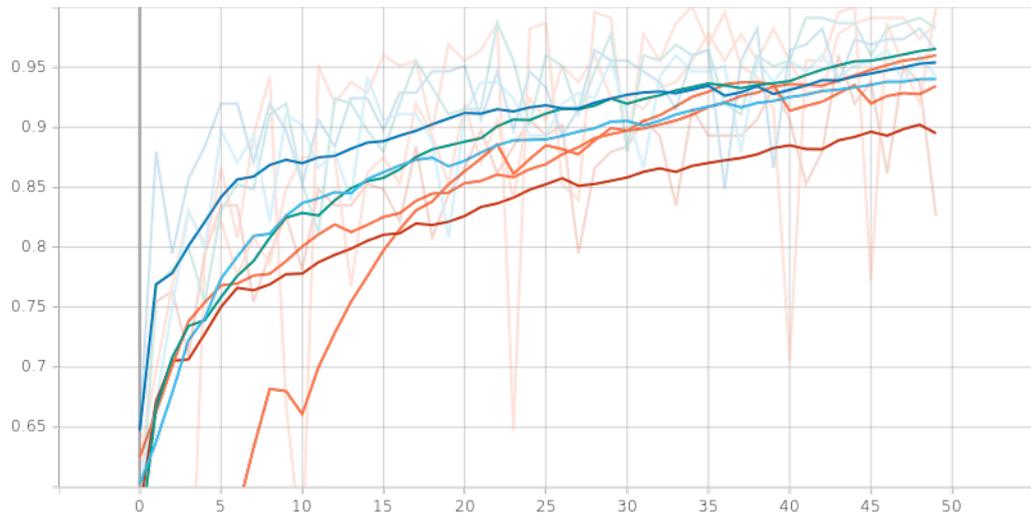


Рис. 5. – Кривые точности для валидационной выборки для самописной сети при разном количестве скрытых слоев и при 5 слоях с применением пакетной нормализации.

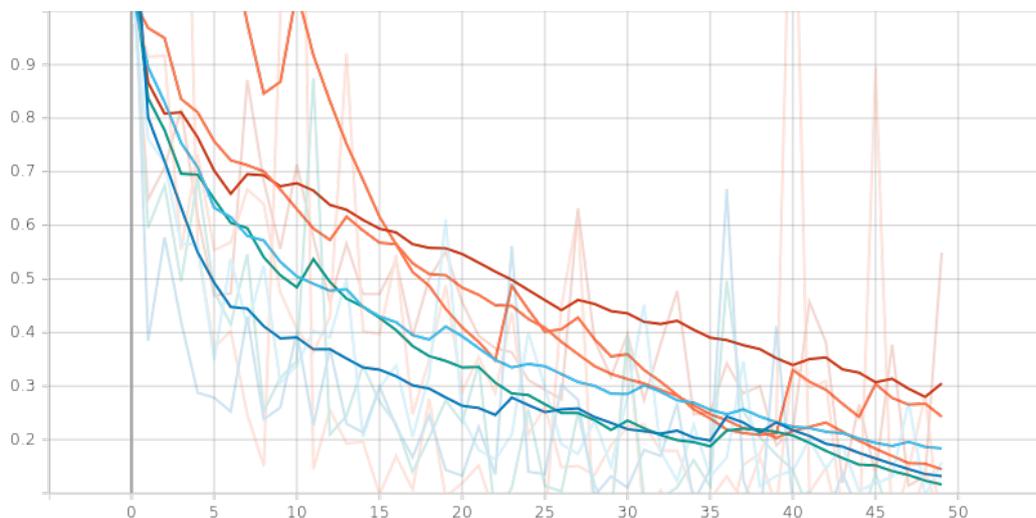


Рис. 6. – Кривые потерь для валидационной выборки для самописной сети при разном количестве скрытых слоев и при 5 слоях с применением пакетной нормализации.

При применении этого метода сеть при 5 слоях показывает резкий рост точности начиная примерно с 10 эпохи, но начиная с 35 эпохи рост почти прекращается, хотя на 50 эпохе точность достаточно высокая. Отсюда можно

заклучить, что в промежутке эпох с 10 до 35, пакетная нормализация показывает себя хорошо, хотя до и после ее действие не выражено.

В результате лучше себя показали модели с 3 слоями и сеть с 5 слоями, но с пакетной нормализацией. Точности этих сетей показывают значения в 0,98 на 50 эпохе.

### Выводы

1. В процессе работы было проведено несколько серий экспериментов. Для кривых моделей известных архитектур ResNet50, VGG16 и MobileNet были построены модели с переносом обучения. Установлено, что точность падает от ResNet50, до MobileNet соответственно.
2. Построена своя кастомная модель, которая также изучалась на предмет изменения параметров. таких как количество скрытых слоев. Наилучший результат сеть показывает при 3 и 4 слоях в 0,98.
3. Изучен характер обучаемости моделей от количества слоев и диапазона эпох. На ранних эпохах показывают быстрый прирост точности кривые с малым количеством слоев, а кривые с большим количеством обучаются медленнее, что связано вероятно с эффектом затухания градиентов.
4. Опробованы методы уменьшения эффекта затухающих градиентов. При этом замена функции активации с relu на tanh заметного эффекта не дало, но применение пакетной нормализации дало выраженный эффект улучшения сети в диапазоне с 35 до 50 эпохи. Наблюдается незначительное переобучение, с которым возможно получится бороться регуляризацией.
5. Реализована модель глубокого обучения по распознаванию болезней яблонь по фотографиям листьев из известного набора данных [4].

## Литература

1. Mahamudul Hashan A., Md Rakib Ul Islam R., Avinash K. Apple leaf disease classification using image dataset: a multilayer convolutional neural network approach. // Informatics And Automation. 2022. №4. pp. 316-318.
  2. Li L, Zhang S, Wang B. Apple Leaf Disease Identification with a Small and Imbalanced Dataset Based on Lightweight Convolutional Networks. // Sensors (Basel). 2021. Vol. 22. №1. p. 173. DOI: 10.3390/s22010173.
  3. Zhang X., Li H., Sun S., Zhang W., Shi F., Zhang R., Liu Q. Classification and Identification of Apple Leaf Diseases and Insect Pests Based on Improved ResNet-50 Model. Horticulturae. 2023. №9. p. 1046. DOI: 10.3390/horticulturae9091046.
  4. J. Arun P., Gopal G. Data for: Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network. Mendeley Data. 2019. V1. DOI: 10.17632/tywbtsjrjv.1.
  5. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. СПб.: Питер, 2018. 480 с.
  6. Хайкин С.Б. Нейронные сети: полный курс. М.: Вильямс, 2006. 1104 с.
  7. Joffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv. 2015. URL: [arxiv.org/abs/1502.03167](https://arxiv.org/abs/1502.03167).
  8. Гудфеллоу Я., Бенджио И., Курвилль И. Глубокое обучение. М.: ДМК Пресс, 2018. 652 с.
  9. Лиля В.Б. Алгоритм и программная реализация адаптивного метода обучения искусственных нейронных сетей. Инженерный вестник Дона. 2012. №1. URL: [ivdon.ru/magazine/archive/n1y2012/626](http://ivdon.ru/magazine/archive/n1y2012/626).
  10. Крон Д., Бейлевельд Г., Аглаэ Б. Глубокое обучение в картинках. Визуальный гид по искусственному интеллекту. СПб.: Питер, 2020. 400 с.
-

## References

1. Mahamudul Hashan A., Md Rakib Ul Islam R., Avinash K. Informatika i avtomatizatsiya. 2022. №4. Pp. 316–318.
2. Li L., Zhang S., Wang B. Sensors (Basel). 2021. Vol. 22. №1. Pp. 173. DOI: 10.3390/s22010173.
3. Zhang X., Li H., Sun S., Zhang W., Shi F., Zhang R., Liu Q. Horticulturae. 2023. №9. Pp. 1046. DOI: 10.3390/horticulturae9091046.
4. J. Arun P., Gopal G. Mendeley Data. 2019. V1. DOI: 10.17632/tywbtsjrv.1.
5. Nikolenko S., Kadurin A., Arkhangelskaya E. Glubokoe obuchenie [Deep Learning]. SPb.: Piter, 2018. 480 p.
6. Khaikin S.B. Neironnye seti: polnyj kurs [Neural Networks: A Comprehensive Foundation]. M.: Williams, 2006. 1104 p.
7. Ioffe S., Szegedy C. arXiv. 2015. URL: [arxiv.org/abs/1502.03167](https://arxiv.org/abs/1502.03167).
8. Goodfellow I., Bengio Y., Courville A. Glubokoe obuchenie [Deep Learning]. M.: DMK Press, 2018. 652 p.
9. Lila V.B. Inzhenernyj vestnik Dona. 2012. №1. URL: [ivdon.ru/magazine/archive/n1y2012/626](http://ivdon.ru/magazine/archive/n1y2012/626).
10. Kron D., Bejleveld G., Aglae B. Glubokoe obuchenie v kartinkakh. Vizual'nyj guid po iskusstvennomu intellektu [Deep Learning Illustrated: A Visual Guide to Artificial Intelligence]. SPb.: Piter, 2020. 400 p.

**Дата поступления: 1.05.2025**

**Дата публикации: 6.06.2025**