

ПРИМЕНЕНИЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ РАЗЛИЧНЫХ ЗАДАЧ В СЕЛЬСКОМ ХОЗЯЙСТВЕ

Г.А. Ососков^{1,2}, А.В. Ужинский², А.В. Нечаевский^{1,2}

¹Государственный университет «Дубна»

²Объединенный институт ядерных исследований

E-mail: gososkov@gmail.com

В сельском хозяйстве технологии искусственного интеллекта применяются для обнаружения проблем развития и выявления болезней растений, прогнозирования урожайности, картографирования, оптимизации использования ресурсов, а также множества других задач. Объединенный институт ядерных исследований обладает профильными специалистами и отличной ресурсной базой для проведения масштабных исследований в области машинного обучения. С 2017 года в ЛИТ ОИЯИ реализуются различные проекты, связанные с применением методов глубокого обучения для решения актуальных задач сельского хозяйства. Периодически к исследованиям привлекаются студенты Государственного университета Дубна и прочих научных организаций. Результатом проводимых работ стали не только оригинальные методы, алгоритмы и подходы, но и программно-аппаратные комплексы, применяемые в реальных условиях.

Ключевые слова: глубокое обучение, искусственный интеллект, сельское хозяйство, автоматизация, распознавание болезней, классификация изображений

В соответствии с большинством прогнозов, к 2050 году население земли превысит 9 миллиардов человек, что неизбежно приведет к необходимости увеличения объемов производства продуктов питания. Нарастить производство и сократить издержки, в том числе из-за потерь, вызванных болезнями растений, можно за счет применения современных технологий, в том числе искусственного интеллекта. В 2017 году группа научных сотрудников Лаборатории информационных технологий ОИЯИ выиграла грант Российского Фонда Фундаментальных Исследований (РФФИ) на разработку комплексной системы диагностирования болезней растений по изображениям и текстовому описанию. На тот момент глубокие сверточные нейронные сети отлично показали себя при решении различных

задач классификации изображений. Модели, обучаемые на данных ImageNet [6], показывали все лучшие и лучшие результаты и к 2017 году были представлены такие известные нейросетевые архитектуры, как ResNet [13] и MobileNet [14]. Активно развивался подход, называемый перенос обучения (transfer learning (TL)), в его рамках использовались уже обученные на множестве изображений сети, у которых заменялась часть, отвечающая за классификацию, и производилось дообучение только новой части. Сверточные сети, бурное развитие которых началось с сети AlexNet, представленной в 2012 году, разработаны для того, чтобы выделять из изображения значимые параметры (features, embeddings), опираясь на которые, можно эффективно решать задачи классификации. При переносе обучения часть базовой сети, отвечающая за выделение значимых параметров, сохраняется, за счет чего можно значительно сократить ресурсы на обучение и получить хороший результат. При использовании переноса обучения необходима база изображений, на которой будет производиться дообучение сети. В 2017 году популярной базой с болезнями растений являлась PlantVillage [15], содержащая 54306 изображений 14 культур и 26 болезней. Существовали работы, использующие актуальные на тот момент нейросетевые архитектуры и базу PlantVillage для переноса обучения. Так, в [18] использовали AlexNet и GoogLeNet, чтобы классифицировать 26 классов болезней и растений, и получили точность 99,35 %. В [26] использовали VGG 16, DenseNet, Inception V4, ResNet с 50, 101, и 152 слоями. Авторы применяли различные техники оптимизации и подходы к обучению и добились точности в районе 98 % для всех архитектур, за исключением VGG 16, точность которой была в районе 82 %. Мы попробовали воспроизвести данный эксперимент на небольшом наборе данных для винограда и получили схожие результаты – точность более 99 % [19]. В процессе экспериментов была собрана небольшая тестовая база изображений из открытых источников для проверки генерализации моделей на реальные условия. Выяснилось, что модели, обученные на данных PlantVillage, на реальных данных показывают очень плохой результат – 48 % точности. Проблема, вероятно, заключалась в синтетической природе изображений PlantVillage – все они выполнены в одном освещении, с одинаковым задним фоном, имеют одинаковую сепарацию

листа и его расположение. Подобные результаты и предположения подтверждались и другими исследованиями [7]. Какое-то время мы пытались решить эту проблему, используя различные подходы к предобработке изображений или использованию только части изображений, но добиться значительных успехов не смогли [1, 11]. В результате от использования базы PlantVillage было решено отказаться. Для обучения моделей, которые можно было бы использовать в реальных условиях, нужно было собирать свою базу. Это требовало инструментов каталогизации изображений, кроме того, нужны были удобные интерфейсы для работы с моделями и средства работы с описанием болезней, рекомендациями по их лечению и запросами пользователей. С целью решения этих задач была создана платформа распознавания болезней растений – pdd.jinr.ru. Изображения в базу собирались из открытых источников. В первой версии базы было всего 350 изображений для пяти классов листьев винограда. Минимальное количество изображений на класс было чуть более 30. Применение подхода переноса обучения в условиях столь маленькой выборки не дает нужной точности. Данные сложности описывались в различных исследованиях, использующих базы изображений, собранные в полевых условиях. Например, в [8] и [24] авторы решали задачу классификации болезней томатов и бананов, используя базы изображений с сотнями представителей на один класс, однако лучшая точность моделей составила лишь 83 % и 70 %. В нашем случае все было еще сложнее, так как мы смогли собрать только десятки изображений на класс. Решение было найдено в области применения специализированных подходов к обучению. Сейчас данные подходы называются *one-shot* или *few-shot learning*. Их основной задачей является не обучение модели для распознавания определенного количества классов изображений, а тренировка нейросети для перевода определенных признаков в векторное пространство, в котором расстояния между объектами определяет их принадлежность к одним классам. Типичными представителями подобного подхода являются *сиамские сети* и *Contrastive loss* — функция минимизации потерь. На первом этапе обучается сеть, которая хорошо умеет отделять объекты одного класса от другого, это достигается путем передачи через сеть двух и более изображений одного или разных классов с последующим получением векторов представлений —

изображений в многомерном пространстве свойств. Функция минимизации потерь работает так, что при перераспределении весов сети вектора изображений одного класса оказались ближе друг к другу, а вектора изображений разных классов оказались дальше друг от друга. На рис. 1 представлено отображение в двумерном пространстве векторов-представлений изображений различных классов до обучения и после обучения с применением ContrastiveLoss[4] функции минимизации потерь.

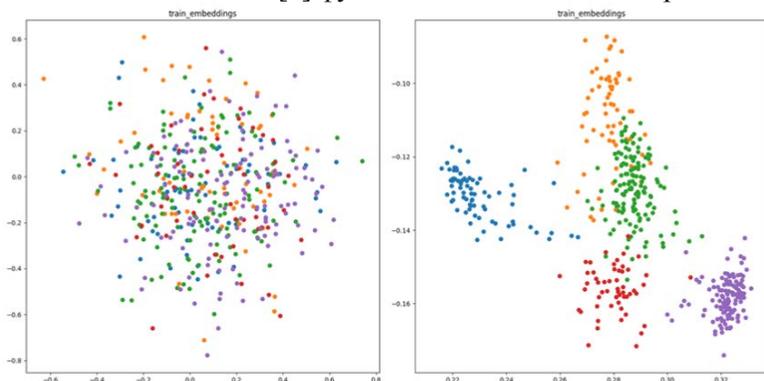


Рис.1. Вектора-представления изображений различных классов до обучения — слева — и после обучения — справа

На первых этапах исследования использовалась оригинальная архитектура сверточной сети всего с несколькими слоями (см. рис 2), но использование ContrastiveLoss функции минимизации потерь позволило добиться точности выше 98 % [12].

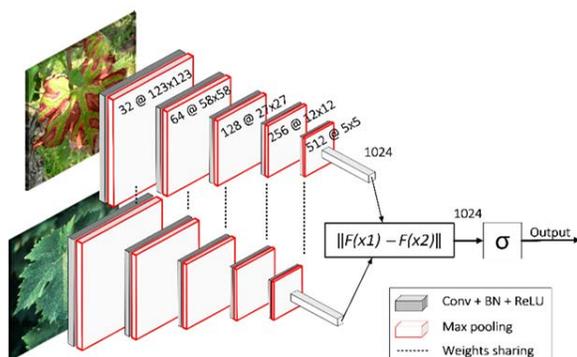


Рис.2. Архитектура сиамской нейронной сети, используемая в первых версиях платформы

Платформа продолжала расширяться, увеличивалось количество изображений и классов болезней в базе. Используемые решения уже не показывали такой хорошей точности. Проводились различные эксперименты в области подбора оптимальных политик аугментации данных, но значимых результатов они не принесли. Следующим важным этапом исследования стало применение в качестве базовой сети, хорошо зарекомендовавшей себя архитектуры MobileNetV2 и трехчленной функции потерь (TripletLoss) [23] (см. рис 3).

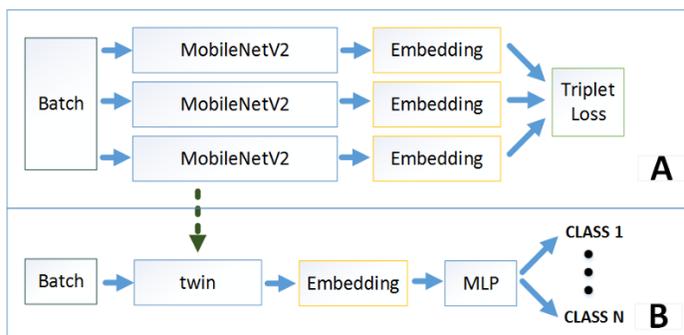


Рис.3. Концепция и архитектура сети, использующей Tripletloss функцию минимизации потерь

При таком подходе на вход подаются два изображения одного класса и одно изображение другого класса. Процесс обучения направлен на подбор весов таким образом, чтобы в многомерном пространстве векторы-представления изображений одного класса стали ближе, а разных классов — максимально удалились друг от друга. В результате на 25 классах удалось добиться точности более 97 % [27]. Подобный подход был использован и для решения достаточно сложной задачи — классификации мхов, где продемонстрировал отличные результаты.

В дальнейшем проводились эксперименты по подбору оптимальной базовой архитектуры. В используемом фреймворке PyTorch представлены различные варианты базовых сетей, и для разных моделей нашей платформы используются разные сети. Также периодически тестируются различные функций минимизации потерь: quadrupleloss[2], ArcFace [6], CosFace [28], SphereFace [16]. В настоящее время для большинства моделей используется ArcFace. Развивалась и сама платформа, в которой сейчас представлена целая коллекция моделей.

На первом шаге обработки запроса пользователя применяется общая модель по болезням и вредителям без привязки к видам и культурам (68 классов). Далее модель, которая определяет вид растения (71 класс). Если для данного вида имеется специализированная модель (27 моделей), то пользователю, в дополнение к общему, будет выдан и частный прогноз. При выдаче результата показываются два наиболее близких класса к загруженному изображению. В большинстве случаев все это позволяет правильно определить болезнь и получить рекомендации по ее лечению. Для взаимодействия с платформой были разработаны мобильные приложения для iOS и Android, Телеграм-бот и программный интерфейс (API) для доступа к возможностям платформы сторонних сервисов. На текущий момент платформой обработано более ста тысяч запросов пользователей. Агрономы анализируют изображения из запросов, которые являются основным источником пополнения базы изображений. Просмотреть все запросы достаточно сложно, поэтому для упрощения обработки новых данных ведутся исследования в области кластеризации данных и semi-supervised learning [29].

Полученные результаты вызвали интерес коллективов различных организаций. Так, схожие алгоритмы классификации были использованы в совместном проекте с научным центром «Агротехнологии будущего» на базе Тимирязевской академии. В нем проводилось исследование влияния света различных спектров на рост культур на определенных стадиях развития. Наши модели использовались для оценки степени развития и весовых групп растений.

Кроме задачи классификации для сельского хозяйства, большой интерес представляют задачи детекции. Если в первой требуется определить, что за болезнь на изображении, то во второй — определить координаты положения объектов на изображении и их классы. Первые эксперименты в данном направлении были связаны с применением RCNN детектора совместно с one-shot классификатора на базе tripletloss функции минимизации потерь [10]. В дальнейшем использовались сети на базе известных архитектур, предназначенных для обнаружения объектов, — YOLO (You Only Look Once) [21] с различными one-shot классификаторами. Таким образом решались задача классификации и подсчета салатов на конвейерных линиях. На первом этапе производилась детекция объектов, а на

втором — их классификация. Данный подход позволил сократить издержки на разметку данных, при этом точность классификации достигла 99 %. С использованием этого же комбинированного алгоритма обработки изображений была решена задача классификации блюд на подносах и оценки стоимости заказа на предприятиях общественного питания (см. рис 4.) [9].

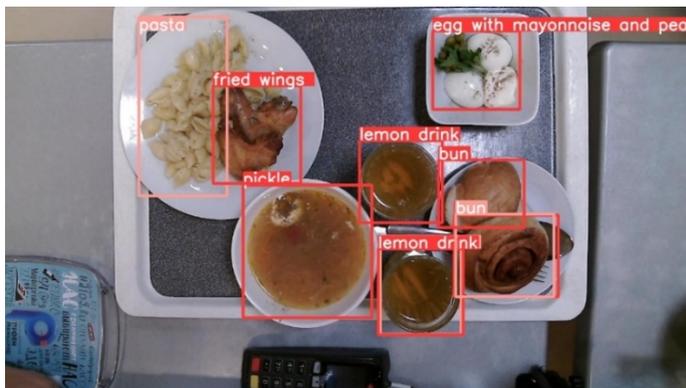


Рис.4. Результат распознавания еды на подносе

В совместном проекте МЛИТ с компанией «Дока-Генные Технологии» разрабатываются механизмы определения различных заболеваний картофеля. Поскольку одна из основных задач компании — выращивание семенного материала, то определение болезней, особенно на ранних стадиях, имеет критически важное значение. Исследования велись сразу по нескольким направлениям. Для определения проблем на полях использовались программно-аппаратные комплексы с камерами высокого разрешения, устанавливаемые на сельхозтехнику. Наибольший интерес вызывают задачи детекции и сегментации. Первая состоит в определении областей изображения, внутри которых находится интересующий объект — растение с признаками болезни. Вторая — выделение областей объектов и определение всех принадлежащих им пикселей. На наборах изображений с тремя видами заболеваний картофеля были апробированы нейросетевые модели семейств YOLO 5, YOLO 7, YOLO 8, YOLO NAS. Последние две модели показали схожие результаты по точности, однако YOLO V8 значительно проще в использовании с программной точкой зрения, так что в основном работа велась именно с ней. В экспериментах использовались модели класса “m-medium”, “s-small” и “n-nano”,

средние показатели точности (mAP50) которых превышают 70%, что позволяет эффективно определять проблемы, используя подходящий минимальный порог сходства распознавания объекта (confidence). Модели s и n больше подходят для онлайн обработки за счет скорости работы. Обработка одного кадра на компьютере с процессором Intel(R) Core(TM) i7-4700HQ CPU @ 2.40GHz 12 GB моделью YOLOv8s в среднем занимает 0.3 секунды, моделью YOLOv8n – 0.14 секунды. Модели сегментации показывают точность на 7-15% хуже, но их можно использовать для подсчета площади зараженных растений в кадре. Однако разметка данных под них требует значительно больше времени, и последующая обработка выходных данных модели более ресурсоемка. Оптимальным вариантом для решения поставленных задач оказались модели детекции YOLO_V8_S.



Рис.5. Примеры изображений с обнаруженными симптомами болезни картофеля

В результате исследований были определены не только наиболее перспективные подходы к обучению моделей, но и апробированы варианты визуализации данных о случаях обнаружения на полях, а также подготовлены рекомендации по программно-аппаратному составу комплекса.

Другое направление исследований — анализ гиперспектральных изображений для поиска закономерностей, позволяющих выявлять больные растения еще до появления видимых симптомов. Данная тема весьма популярна, так, в [20] авторы в контролируемых условиях с достаточно высокой точностью

диагностируют Y-вирус у картофеля. Основным источником данных нашего исследования являлась гиперспектральная камера Cubert, производящая съемку в 128 каналах (длины волн от 420 до 1000 нм). Разрешение камеры 50x50 пикселей. Таким образом, основной объект представляет собой вектор 50x50x128. В дополнение камера выдает монохромный снимок 1000x1000. Сеансы съемки производились на регулярной основе и выполнялись в контролируемых условиях: освещение, положение растений, сепарация и т.д. Проведенные исследования подтвердили возможность использования различных нейросетевых и статистических алгоритмов для классификации гиперспектральных изображений больного и здорового картофеля различных сортов. В ходе реализации проекта были отработаны подходы к разметке данных, позволяющие обучать различные модели и производить их валидацию, разработаны и апробированы различные варианты предобработки данных и определены наиболее перспективные из них, определены комбинации спектральных каналов, позволяющие получить вегетационный индекс, наиболее ярко показывающий признаки болезни [22]. Классический NDVI индекс вычисляется по форме $(NIR-R)/(NIR+R)$, где NIR – значение в инфракрасном канале, а R – в красном. Мы работали с гиперспектральной камерой, и возможностей выбора каналов у нас было более 100, так что и их вариаций могло быть очень много. В результате для поиска перспективных комбинаций каналов использовался как прямой перебор, так и автоматический алгоритм, который производил статистическое сравнение наборов больных и здоровых растений. В контролируемых условиях удалось добиться надежного разделения классов (см. рис. 6).

В ходе исследования были реализованы и апробированы различные статистические и нейросетевые модели классификации. Статистические модели, основанные на XGBoost [3] и опирающиеся на данные из множества каналов, показали большую точность, при этом хуже работают на разных сортах картофеля. Нейросетевые модели, основанные на one-shot классификаторах и использующие индексы, показали несколько меньшую точность относительно статистических, однако они используют всего несколько каналов и лучше работают с разными сортами.

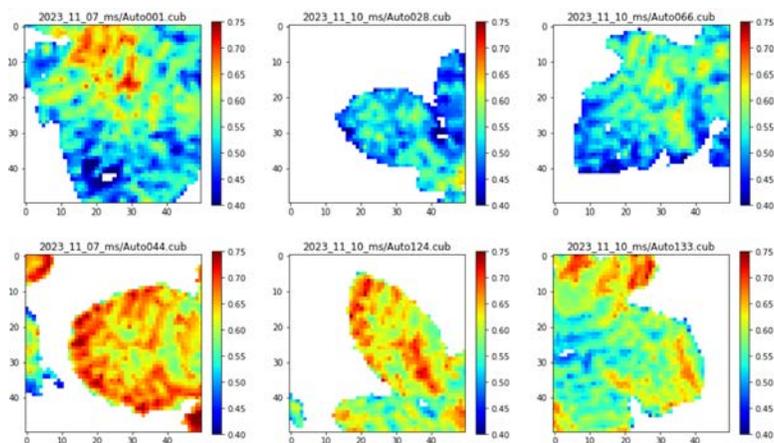


Рис. 6. Индекс для больных — верхний ряд — и здоровых — нижний ряд растений 50x50 ($r=65$, $nir = 98$)

Работа со спектральными камерами требует высокой точности организации процесса, так как внешние факторы способны вносить искажения, достаточные для смешения классов. Для переноса результатов в менее контролируемую среду требуются дополнительные исследования параметров обработки изображений, при которых можно добиться четкого визуального расхождения классов, которое могло бы сохраняться при воздействии внешних факторов. На текущий момент наиболее перспективным направлением является работа с rgb-изображениями.

Еще одно активно развивающееся направление исследований — автоматизация анализа состояния растений в тепличных комплексах. Основной задачей проекта является автоматизация рутинных операций агрономов и предоставление им удобных инструментов учета и мониторинга. В данной области предложены интересные подходы [17] и [25], однако ряд задач в них остается нерешенным. В ходе реализации нашего проекта разрабатывается автономная роботизированная платформа, способная передвигаться по различным типам поверхностей, фиксировать интересующие показатели и выполнять съемку на большой высоте. Результатом работы должен стать цифровой двойник тепличного комплекса, в котором будет показана актуальная информация по количеству растений в ряду и их характеристикам, обнаруженные проблемы, данные по различным

показателям (температура, влажность, освещенность) и прочее. Проект сочетает в себе решение различных технических задач по проектированию и разработке элементной базы платформы, робототехнических задач — картирование, локализация, автономное передвижение, выполнение маршрутных заданий, организационных задач — обработка изображений, отображение результата на карте и нейросетевых задач — отслеживание и подсчет, классификация, локализация и идентификация болезней и вредителей.

В настоящее время разработаны полнофункциональный прототип роботизированной платформы, прототип комплекса контроля и учета и ряд моделей для подсчета растений, оценки состояния растений, обнаружения вредителей и признаков некоторых болезней (см. рис. 7). В текущем сезоне планируется тестирование прототипа на базе одного из тепличных комплексов в Калужской области.



Рис.8. Слева – работа модели подсчета растений в ряду, справа – полнофункциональный прототип комплекса

Использование искусственного интеллекта и автоматизации в сельском хозяйстве позволяет увеличить урожай и уменьшить издержки. На базе ЛИТ ОИЯИ проводятся масштабные исследования, имеющие не только научную, но и практическую значимость. Результатом работ являются как оригинальные методы, алгоритмы и подходы, так и программно-аппаратные комплексы, уже сейчас применяемые в реальных условиях. К работе над проектами активно привлекаются учащиеся различных институтов и университетов, в том числе Государственного университета «Дубна».

Существенный вклад в исследования внесли аспирант Павел Гончаров и студенты: Артем Сметанин, Михаил Герасимчук, Евгения Резвая и Артем Дорохин.

Список литературы

1. Резвая Е.П., Гончаров П.В., Ососков Г.А., ПРИМЕНЕНИЕ МЕТОДОВ ДОМЕННОЙ АДАПТАЦИИ В ЗАДАЧЕ КЛАССИФИКАЦИИ РАСТЕНИЙ ПО ИЗОБРАЖЕНИЯМ ИХ ЛИСТЬЕВ, Системный анализ в науке и образовании, №2, 2020, изд. Университет "Дубна"
2. Chen W., Chen X., Zhang J. and Huang K., "Beyond Triplet Loss: A Deep Quadruplet Network for Person Re-identification," in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017 pp. 1320-1329. doi: 10.1109/CVPR.2017.145
3. Chen T., Guestrin C., Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining; 2016 pp. 785–794.
4. Chopra S., Hadsell R. and LeCun Y., "Learning a similarity metric discriminatively, with application to face verification," 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, CA, USA, 2005, pp. 539-546 vol. 1, doi: 10.1109/CVPR.2005.202.
5. Deng J., Dong W., Socher R., Li L.-J., Li K. and Li F.-F., "ImageNet: A large-scale hierarchical image database," 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 2009, pp. 248-255, doi: 10.1109/CVPR.2009.5206848.
6. Deng J., Guo J., Xue N. and Zafeiriou S., ArcFace: Additive Angular Margin Loss for Deep Face Recognition, 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019, pp. 4685-4694, doi: 10.1109/CVPR.2019.00482.
7. Ferentinos, K.P. 2018 Deep learning models for plant disease detection and diagnosis. *Comput. Electron. Agric.* 145, p. 311–318.
8. Fuentes, A., Yoon, S., Kim, S., Park, D. 2017 A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors* 17
9. Gerasimchuk M., Uzhinskiy A., Recognition for Smart Restaurants and Self-Service Cafes // *Physics of Particles and Nuclei Letters*, 2024, Vol. 21, No. 1, pp. 79–83.
10. Gerasimchuk M., Uzhinskiy A., R-CCN Plant Diseases Detector Using Triples Loss and Siamese Neural Networks. // *Physics of Particles and Nuclei Letters*, 2022, Vol. 19, No. 5, pp. 570–573.
11. Goncharov P., Nestsiarenia I., Ososkov G., Nechaevskiy A., Uzhinskiy A., DISEASE DETECTION ON THE PLANT LEAVES BY

- DEEP LEARNING, *Advances in Neural Computation, Machine Learning, and Cognitive Research II*, Springer, 2018, p. 151-159, DOI: 10.1007/978-3-030-01328-8_16
12. Goncharov P., Uzhinskiy A., Ososkov G., Nechaevskiy A., Zudikhina J., 2020 Deep Siamese Networks for Plant Disease Detection, *Mathematical Modeling and Computational Physics 2019*, EPJ Web of Conferences, p 2-4 DOI:<https://doi.org/10.1051/epjconf/202022603010>
 13. He K., Zhang X., Ren S. and Sun J., "Deep Residual Learning for Image Recognition," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
 14. Howard, A. G. et al. "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications." ArXiv abs/1704.04861 (2017)
 15. Hughes, D., Salathé, M., 2015 An open access repository of images on plant health to enable the development of mobile disease diagnostics through machine learning and crowdsourcing. *CoRR*, vol abs/1511.08060.
 16. Liu W., et al., "SphereFace: Deep Hypersphere Embedding for Face Recognition," in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017 pp. 6738-6746. doi: 10.1109/CVPR.2017.713
 17. Martin J., Ansuategi A., Maurtua I., Gutierrez A., Obregón D., Casquero O., Marcos M., A Generic ROS-Based Control Architecture for Pest Inspection and Treatment in Greenhouses Using a Mobile Manipulator. *IEEE Access* 2021, 9, 94981–94995
 18. Mohanty, S, Hughes, D, Salathé, M., 2016 Using deep learning for image-based plant disease detection. *Front. Plant Sci.* 7, 1419. 9 8.
 19. Ososkov G., Nechaevskiy A., Uzhinskiy A., Goncharov P., ARCHITECTURE AND BASIC PRINCIPLES OF THE MULTIFUNCTIONAL PLATFORM FOR PLANT DISEASE DETECTION, *CEUR Workshop Proceedings. GRID 2018 - Selected Papers of the 8th International Conference "Distributed Computing and Grid-Technologies in Science and Education. 2018. C. 200-206.*
 20. Polder G., Blok P.M., de Villiers H.A.C., van der Wolf J.M., Kamp J., Potato Virus Y Detection in Seed Potatoes Using Deep Learning on Hyperspectral Images. *Front. Plant Sci.* 2019, 10, 209.
 21. Redmon J., Divvala S., Girshick R. and Farhadi A., "You Only Look Once: Unified, Real-Time Object Detection," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 779-788, doi: 10.1109/CVPR.2016.91.
 22. Rouse J.W, Haas R.H., Scheel J.A., Deering D.W., Monitoring Vegetation Systems in the Great Plains with ERTS. *Proceedings, 3rd*

- Earth Resource Technology Satellite (ERTS) Symposium; 1974 vol. 1, p. 48-62
23. Schroff F., Kalenichenko D., Philbin J., FaceNet: A unified embedding for face recognition and clustering. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2015: 815-823. DOI: 10.1109/CVPR.2015.7298682.
 24. Selvaraj M., Vergara A., Ruiz H., Safari N., Elayabalan S., Ocimati W., Blomme G. 2019 AI-powered banana diseases and pest detection. *Plant Methods* 15, 92.
 25. Tiwari S., Zheng Y., Pattinson M., Campo-Cossio M., Arnau R., Obregon D., Ansuategui A., Approach for Autonomous Robot Navigation in Greenhouse Environment for Integrated Pest Management. In Proceedings of the IEEE/ION Position, Location and Navigation Symposium (PLANS), Portland, OR, USA, 20–23 April 2020; pp. 1286–1294.
 26. Too E.C., Yujian L., Njuki S., Yingchun L., 2019 A comparative study of fine-tuning deep learning models for plant disease identification. *Comput. Electron. Agric.* 161, p 272–279.
 27. Uzhinskiy A., Ososkov G., Goncharov P., Nechaevskiy A., Smetanin A., One-shot learning with triplet loss for vegetation classification tasks. *Computer Optics* 2021; 45(4): 608-614. DOI: 10.18287/2412-6179-CO-856.
 28. Wang H. et al., "CosFace: Large Margin Cosine Loss for Deep Face Recognition," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018, pp. 5265-5274, doi: 10.1109/CVPR.2018.00552.
 29. Yang X., Song Z., King I. and Xu Z., "A Survey on Deep Semi-Supervised Learning," in *IEEE Transactions on Knowledge and Data Engineering*, vol. 35, no. 9, pp. 8934-8954, 1 Sept. 2023, doi: 10.1109/TKDE.2022.3220219.