

UDK 004.8.032.26

DOI

Бийбосунов Б.И.,
доктор технических наук, профессор
bbolotbek@mail.ru¹

Сабитов Б.Р.,
кандидат технических наук, профессор
sabitovbr@kstu.kg¹

*Кыргызский государственный университет
имени И. Арабаева,
720026, Бишкек, ул. Раззакова, 51а¹*

МЕТОДЫ МАШИННОГО И ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ЗАДАЧ ЦИФРОВОГО СЕЛЬСКОГО ХОЗЯЙСТВА

Аннотация. Исследована задача влияния изменение климата на различные экологические и аграрные системы. В качестве инструмента исследования было выбрано машинное и глубокое обучение как элементы искусственного интеллекта. С помощью множества алгоритмов машинного обучения моделируется высокоуровневые абстракции в данных, которые представляют собой нелинейные преобразования.

На базе архитектур машинного и глубокого обучения построены нейронные сети обнаружения болезней растений и вредителей в виде веб-приложений. Создано программное обеспечение для распознавания изображений. Архитектуры, построенные для обнаружения болезней и вредителей растений, основанные на машинном и глубоком обучении, имеют не только важное академическое исследовательское значение, но и имеет очень широкую перспективу рыночного применения в задачах сельского хозяйства.

Ключевые слова: машинное обучение, глубокое обучение, сельское хозяйство, искусственный интеллект, нейросети, болезни растений.

Введение

Глобальная задача машинного обучения — создать искусственный интеллект, который по своим аналитическим способностям будет равен или даже превосходить человеческий разум. Это очень сложная задача, которую тем не менее наука вполне может решить в ближайшие годы. Задачи машинного обучения можно разделить на четыре большие группы: классическое обучение, ансамблевые методы, обучение с подкреплением, нейросети и глубокое обучение.

Рассматриваются наиболее распространенные в научных исследованиях методы классификации, регрессии, кластеризации и уменьшение размерности. Классификация используется для решения тех задач, где на основании признаков объектов требуется распределить их по заданным категориям. Например, в сельском хозяйстве распознать здоровый лист растения от нездорового. На производстве могут отделять детали с браком от хороших с помощью компьютерного зрения. Регрессия в теории вероятностей и математической статистике – это зависимость среднего значения какой-либо величины от некоторой другой величины или от нескольких величин. В задачах регрессии с помощью алгоритмов машинного обучения можно анализировать огромные массивы данных и делать прогнозы на их основе. Например, можно загрузить в компьютер данные об урожайности за последние 10 -20 лет и прогнозировать урожайность культур в текущем или последующие годы. Важная группа задач – кластеризация. Кластеризация – это распределение объектов по категориям, когда неизвестно, сколько категорий получится в итоге. Распределение происходит по заданному критерию. Например, кластеризацию можно использовать в задачах распознавания типов болезней растений по различным сельскохозяйственным культурам и на их основе прогнозировать какой группой болезнью болеют определенный класс растений. Например, компания может использовать кластеризацию для определения типов клиентов по паттернам их покупок и делать на основании этого персонализированные предложения товаров. Следующая сложная задача - уменьшение размерности или проклятие размерности. Уменьшение размерности помогает сократить количество признаков в данных без потери информации. Это упрощает их обработку и ускоряет алгоритмы машинного обучения, так как количество данных, с которыми им предстоит работать, уменьшается. При распознавании изображений снижение размерности позволяет не анализировать каждый пиксель, а использовать только важные признаки. Например, чтобы распознать лист растения достаточно обнаружить желтые или бурые пятна или распознать больной лист растения среди здоровых.

Обзор литературы.

Обнаружение болезней и вредителей растений является одной из важных подзадач исследований в области машинного зрения. Это технология, которая использует методы машинного зрения для получения изображений, чтобы определить, есть ли болезни и вредители на собранных изображениях растений [1 -[14](#)]. В настоящее время технологии для обнаружения болезней растений и вредителей на основе машинного зрения первоначально применялись в сельском хозяйстве и в некоторой степени заменило традиционную идентификацию невооруженным глазом.

Для традиционного метода обнаружения болезней растений и вредителей на основе машинного зрения часто используются обычные алгоритмы обработки изображений или ручное проектирование признаков плюс классификаторы [2-[15](#)]. Этот тип метода обычно использует

различные свойства болезней и вредителей растений для разработки схемы изображения и выбирает соответствующий источник света и угол съемки, что помогает получать изображения с равномерным освещением. Хотя тщательно построенные схемы визуализации могут значительно снизить сложность разработки классического алгоритма, они также увеличивают стоимость приложения. В то же время в естественных условиях часто нереально ожидать, что классические алгоритмы призваны полностью исключить влияние смены сцены на результаты распознавания [3- [16](#)]. В реальной сложной природной среде обнаружение болезней растений и вредителей сталкивается со многими проблемами, такими как небольшая разница между площадью поражения и фоном, низкая контрастность, большие различия в масштабе области поражения и различных типов, много шума. на изображении поражения. Также много помех при сборе изображений болезней и вредителей растений в условиях естественного освещения. В это время традиционные классические методы часто оказываются бессильными, и добиться лучших результатов обнаружения сложно.

В последние годы, успешно применяются модели глубокого обучения, представленные сверточной нейронной сетью (CNN), которые нашли применения во многих областях компьютерного зрения таких как, обнаружение трафика [4], распознавание медицинских изображений [5], распознавание текста сценария [6], распознавание выражений лица [7], распознавание зрачка глаза [8].

Методология

На рис.1. показана структура машинного обучения в целом.

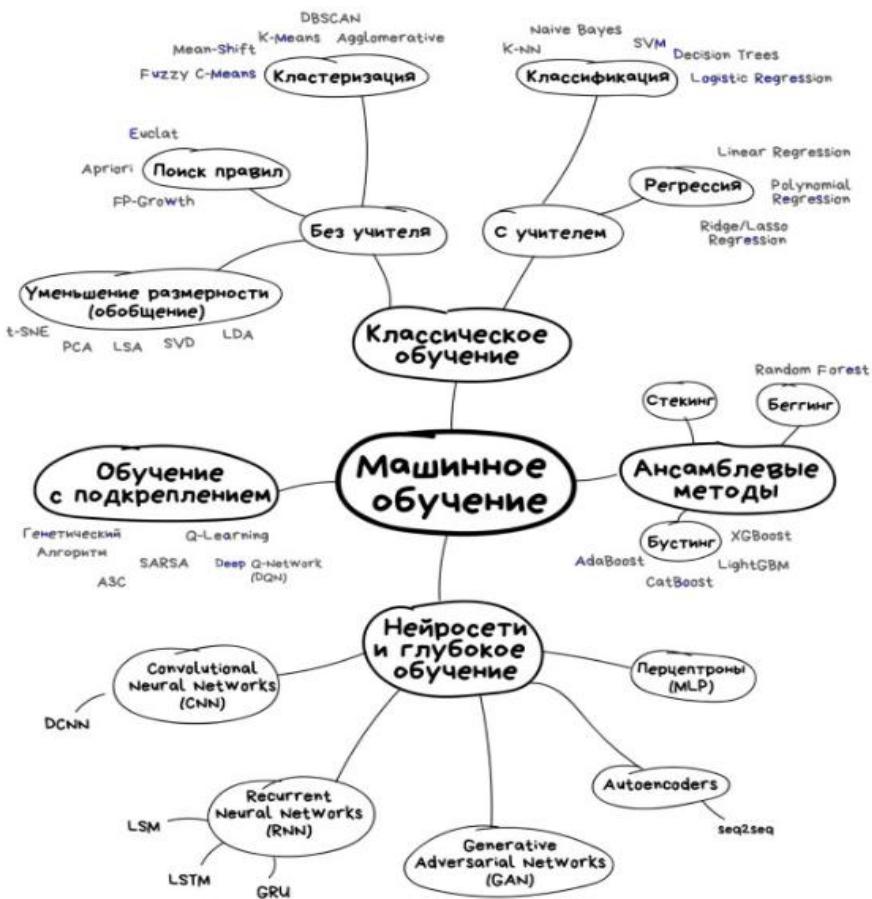


Рис.1 - Структура машинного обучения

В данной статье подробно рассмотрены основные алгоритмы машинного обучения и их применение к задачам сельского хозяйства. Рассмотрены математическое описание и процесс реализации алгоритмов машинного обучения для построения различных моделей сельского хозяйства. Важным разделом машинного обучения является построения линейных и нелинейных моделей. Например, для построения линейной модели используются одномерная и множественная регрессия, различные варианты логистической регрессии, а также полиномиальная регрессия.

Регрессионные задачи машинного обучения относятся к методам обучения с учителем. Они используются для решения задач регрессии. Регрессия - процесс поиска модели, которая предсказывает непрерывное значение на основе входных переменных. Например, он прогнозирует непрерывные значения, такие как температура, цена, продажи, зарплата и возраст. Границы использования данного алгоритма очень широкие. Линейная регрессия в основном используется для поиска линейной связи между целью и одним или несколькими предикторами. Другими словами, он предсказывает целевую переменную, подбирая линейную связь между зависимой (целевой переменной) и независимыми переменными (предикторами). Кроме того, он используется для прогнозирования и выяснения причинно-следственных связей между переменными.

Результаты

Постановка задачи. Болезни и вредители растений — это один из видов стихийных бедствий, которые влияют на нормальный рост растений и

даже вызывают гибель растений в течение всего процесса роста растений от развития семян до всходов и до роста сеянцев. В задачах машинного зрения болезни растений и вредители, как правило, являются понятиями человеческого опыта, а не чисто математическими определениями.

Определение болезней растений и обнаружение вредителей

По сравнению с определенными задачами классификации, обнаружения и сегментации в компьютерном зрении [9], требования обнаружения болезней растений и вредителей очень общие. По сути, его требования можно разделить на три различных уровня: что, где и как [10]. На рис.2. представлены методы исследования и обнаружения болезней расетний на основе глубокого обучения.

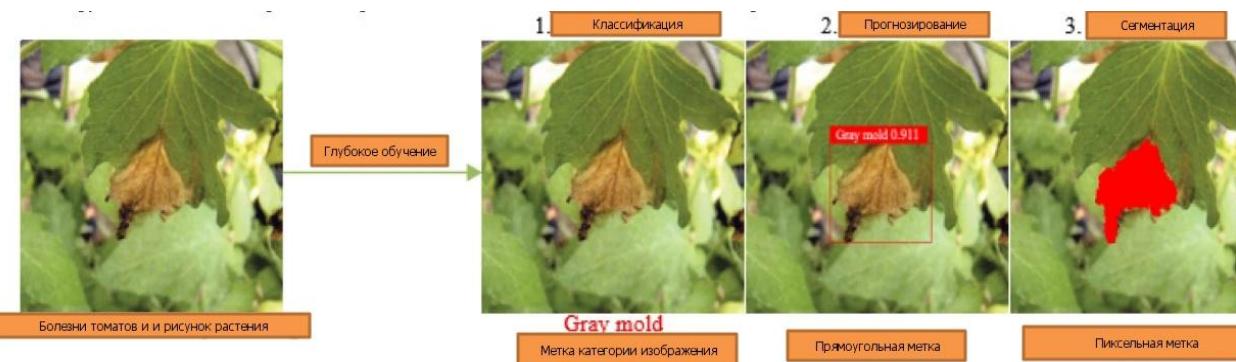


Рис.2 - Обнаружения болезней и вредителей растений (болезнь Gray mold - серая плесень)

Сравнение с традиционными методами обнаружения болезней и вредителей растений. Чтобы лучше проиллюстрировать характеристики методов обнаружения болезней и вредителей растений, основанных на глубоком обучении, согласно существующим источникам [11 , 12], дано сравнение с традиционными методами обнаружения болезней и вредителей растений.

Технология распознавания изображений на основе глубокого обучения. По сравнению с другими методами распознавания изображений технология распознавания изображений, основанная на глубоком обучении, не требует выделения конкретных признаков, и только посредством итеративного обучения можно найти соответствующие признаки, которые могут приобретать глобальные и контекстуальные признаки изображений, а также обладают высокой надежностью и более высоким уровнем точности распознавания.

Теория глубокого обучения. Концепция глубокого обучения – DeepLearning (DL) возникла из статьи, опубликованной в журнале Science Hinton et al. [13 -29] в 2006 году. Основная идея глубокого обучения заключается в использовании нейронной сети для анализа данных и изучения признаков. Признаки данных извлекаются несколькими скрытыми слоями, каждый скрытый слой можно рассматривать как персепtron, персепtron используется для извлечения низкоуровневых данных функций, а затем

комбинировать низкоуровневые функции для получения абстрактных высокоуровневых функций, что может значительно облегчить проблему локального минимума. Глубокое обучение преодолевает тот недостаток, что традиционные алгоритмы полагаются на искусственно созданные функции, и привлекает все больше и больше внимания исследователей. В настоящее время он успешно применяется в компьютерном зрении, распознавании образов, распознавании речи, обработке естественного языка и системах рекомендаций [14 -[30](#)].

Традиционные методы классификации изображений и распознавания признаков ручного проектирования могут извлекать только основные признаки, и сложно извлечь глубокую и сложную информацию о свойствах изображения [15 -[31](#)]. И метод глубокого обучения может решить это узкое место. Он может напрямую проводить неконтролируемое обучение на исходном изображении для получения информации о многоуровневых функциях изображения, таких как функции низкого уровня, промежуточные функции и семантические функции высокого уровня. Традиционные алгоритмы обнаружения болезней растений и вредителей в основном используют метод распознавания изображений с элементами, созданными вручную, что сложно и зависит от опыта и удачи, и не может автоматически изучать и извлекать признаки из исходного изображения. Напротив, глубокое обучение может автоматически извлекать функции из больших данных без ручной обработки. Модель состоит из нескольких слоев, обладает хорошей автономной способностью к обучению и способностью выражать признаки, а также может автоматически извлекать признаки изображения для классификации и распознавания изображений. Следовательно, Глубокое обучение может сыграть большую роль в области распознавания изображений болезней растений и вредителей. В настоящее время методы глубокого обучения разработали множество хорошо известных моделей глубоких нейронных сетей, включая глубокую сеть доверия (DBN), глубокую машину Больцмана (DBM), автоэнкодер с шумоподавлением стека (SDAE) и глубокую сверточную нейронную сеть (CNN).[16 -[32](#)]. В области распознавания изображений использование этих моделей глубоких нейронных сетей для реализации автоматического извлечения признаков из многомерного пространства признаков дает значительные преимущества по сравнению с традиционными методами извлечения признаков вручную. Кроме того, по мере роста количества обучающих выборок и увеличения вычислительной мощности возможности характеристизации глубоких нейронных сетей продолжают улучшаться. В настоящее время бум глубокого обучения охватывает как промышленность, так и научные круги, а производительность моделей глубоких нейронных сетей значительно опережает традиционные модели. В последние годы самой популярной средой глубокого обучения является глубокая сверточная нейронная сеть.

Сверточная нейронная сеть. Сверточные нейронные сети, сокращенно CNN, имеют сложную сетевую структуру и могут выполнять операции свертки. Как показано на рис. 3, модель сверточной нейронной сети состоит

из входного слоя, слоя свертки, слоя объединения, слоя полного соединения и выходного слоя. В одной модели слой свертки и слой объединения чередуются несколько раз, и когда нейроны слоя свертки соединены с нейронами слоя объединения, полного соединения не требуется. CNN — популярная модель в области глубокого обучения. Причина кроется в огромной емкости модели и сложной информации, вызванной основными структурными характеристиками CNN, что позволяет CNN играть преимущество в распознавании изображений. В то же время успехи CNN в задачах компьютерного зрения способствовали росту популярности глубокого обучения.

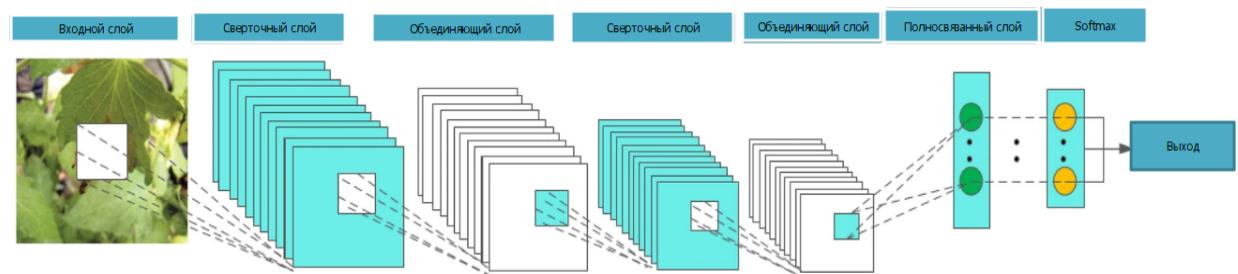


Рис. 3 - Базовая структура CNN

В слое свертки сначала определяется ядро свертки. Ядро свертки можно рассматривать как локальное рецептивное поле, а локальное рецептивное поле является самым большим преимуществом нейронной сети свертки. При обработке информации о данных ядро свертки скользит по карте объектов, чтобы извлечь часть информации об объектах. После извлечения признаков из слоя свертки нейроны вводятся в объединяющий слой для повторного извлечения признаков. В настоящее время широко используемые методы объединения включают вычисление средних, максимальных и случайных значений всех значений в локальном рецептивном поле. После поступления данных в несколько слоев свертки и слоев пула они попадают в слой полного соединения, а нейроны слоя полного соединения полностью связаны с нейронами верхнего слоя. Наконец, данные в слое полного соединения могут быть классифицированы методом softmax, а затем значения передаются на выходной слой для вывода результатов.

Инструменты с открытым исходным кодом для глубокого обучения.

Обычно используемые сторонние инструменты с открытым исходным кодом для глубокого обучения — это Tensorflow [17 -[35](#)], Torch/PyTorch [18 [36](#)], Caffe [19 -[37](#)], Theano [20 -[38](#)]. Все четыре широко используемых сторонних инструмента глубокого обучения с открытым исходным кодом поддерживают кроссплатформенную работу, а платформы, которые можно запускать, включают Linux, Windows, iOS, Android. Torch/PyTorch и Tensorflow обладают хорошей масштабируемостью и поддерживают большое количество сторонних библиотек и структур глубокой сети, а также имеют

самую высокую скорость обучения при обучении больших сетей CNN на графическом процессоре.

Методы обнаружения болезней и вредителей растений на основе глубокого обучения.

В этом разделе дается краткий обзор методов обнаружения болезней и вредителей растений, основанных на глубоком обучении. Поскольку достигнутая цель полностью соответствует задаче компьютерного зрения, методы обнаружения болезней и вредителей растений, основанные на глубоком обучении, можно рассматривать как применение актуальных классических сетей в области сельского хозяйства.

Классификационная сеть. В реальной природной среде большие различия в форме, размере, текстуре, цвете, фоне, расположении и освещении изображений болезней растений и вредителей затрудняют распознавание. Из-за сильных возможностей CNN по извлечению признаков принятие сети классификации на основе CNN стало наиболее часто используемым шаблоном для классификации болезней растений и вредителей. Как правило, часть извлечения признаков классификационной сети CNN состоит из каскадного слоя свертки + слоя объединения, за которым следует слой полного соединения (или средний слой объединения) + структура softmax для классификации. Существующие сети классификации болезней и вредителей растений в основном используют мутные сетевые структуры в компьютерном зрении, включая AlexNet [21 -[39](#)], GoogleLeNet [22-[40](#)], ResNet [23 -[42](#)], DenseNets [24 -[44](#)]. Есть также некоторые исследования, которые разработали сетевые структуры, основанные на практических задачах.

Вводя тестовое изображение в классификационную сеть, сеть анализирует входное изображение и возвращает метку, которая классифицирует изображение. В соответствии с различием задач, решаемых с помощью метода сети классификации, его можно разделить на три подкатегории: использование сети в качестве экстрактора признаков, использование сети непосредственно для классификации и использование сети для определения местоположения поражений.

Заключение

В данной работе проведено исследование применения различных алгоритмов и методов машинного обучения и методов глубокого обучения для широкого круга сельскохозяйственных задач. В настоящее время роль искусственного интеллекта в прикладных исследованиях занимает особое место. Одним из архиважных задач для нашей страны, и вообще в мире, является продовольственная безопасность. Ключевым фактором для повышения урожайности кроме, погодных условий и технологий выращивания является борьба с болезнями растений. Распознавания и классификации болезней сельскохозяйственных растений является основой получения желаемого урожая фермеров.

Некоторые методы обнаружения болезней растений и вредителей, основаны на глубоком обучении. Оно применяется в реальных

сельскохозяйственных задачах. На базе архитектур глубокого обучения построены нейронные сети обнаружения болезней растений и вредителей в виде веб-приложения. Создано программное обеспечение для распознавания изображений. Архитектуры, построенные для обнаружения болезней и вредителей растений, основанные на глубоком обучении, имеют не только важное академическое исследовательское значение, но и имеет очень широкую перспективу рыночного применения в задачах сельского хозяйства.

ЛИТЕРАТУРА

1. **You, J.** “Deep gaussian process for crop yield prediction based on remote sensing data” [Text] / J.You, X.Li, M.Low et al. // In Thirty-First AAAI Conf.on Artificial Intel. – 2017. – P.4559–4566.
2. **Lee, S.H.** How deep learning extracts and learns leaf features for plant classification [Text] / S.H.Lee, C.S.Chan, S.J.Mayo et al.// Pattern Recogn. – 2017. – Vol.71. – P.1–13.
3. **Tsaftaris, S.A.** Machine learning for plant phenotyping needs image processing [Text] / S.A.Tsaftaris, M.Minervini, H.Scharr et al. // Trends Plant Sci. – 2016. – Vol.21(12). – P.989–91.
4. **Fuentes, A.** Deep learning-based techniques for plant diseases recognition in real-field scenarios [Text] / A. Fuentes, S.Yoon, D.S.Park // In: Advanced concepts for intelligent vision systems. – 2020. – P.
5. **Yang, D.** MF-CNN: traffic flow prediction using convolutional neural network and multi-features fusion [Text] / D.Yang, S.Li, Z.Wang et al. // IEICE Trans Inf Syst. – 2019. – Vol.102 (8). – P.1526–36.
6. **Sundararajan, S.K.** Deep belief cnn feature representation based content based image retrieval for medical images [Text] / S.K.Sundararajan, B.Sankaragomathi, D.S.Priya et al. // J.Med Syst. – 2019. – Vol.43(6). – P.1–9.
7. **Melnyk, P.** A high-performance CNN method for offline handwritten chinese character recognition and visualization [Text] / P.Melnyk, Z.You, K.Li. // Soft Comput. – 2019. – Vol.24. – P.7977–87.
8. **Li, J.** CNN-based facial expression recognition from annotated rgb-d images for human–robot interaction [Text] / J.Li, Y.Mi, Z.Ju // Int J Humanoid Robot. - 2019. – Vol.16 (04). – P.504–5.
9. **Kumar, S.** Occluded thermal face recognition using bag of CNN(BoCNN) [Text] / S.Kumar, S.K.Singh // IEEE Signal Process Lett. – 2020. – Vol.27. – P.975.
10. **Wang, X.** Deep learning in object recognition, detection, and segmentation [Text] / X.Wang // Found Trends Signal Process. – 2016. – Vol.8(4). – P.217–382.
11. **Boulent, J.** Convolutional neural networks for the automatic identification of plant diseases [Text] / J.Boulent, S.Foucher, J.Theau et al. // Front Plant Sci. – 2019. – Vol.10. – P.941.
12. **Kumar, S.** Plant disease detection using image processing—a review [Text] / S.Kumar, R.Kaur // Int J Comput Appl. – 2015. – Vol.124 (2). – P.6–9.

13. **Shekhawat, R.S.** Review of image processing approaches for detecting plant diseases [Text] / R.S.Shekawat, A.Sinha // IET Image Process. – 2020. – Vol.14(8). – P.1427–39.
14. **Hinton, G.E.** Reducing the dimensionality of data with neural networks [Text] /G.E.Hinton, R.Salahutdinov // Science. – 2006. – Vol.313 (5786). – P.504–7.
15. **Liu, W.** A survey of deep neural network architectures and their applications [Text] / W.Liu, Z.Wang, X.Liu et al. // Neurocomputing. – 2017. – Vol.234. – P.11–26.
16. **Fergus, R.** Deep learning methods for vision [Электронный ресурс] / R.Fergus // CVPR 2012 Tutorial. – Режим доступа: www.cs.toronto.edu/~ranzato. – Загл.с экрана.
17. **Zeiler, M.D.** Stochastic pooling for regularization of deep convolutional neural networks [Text] / M.D.Zeiler, R.Fergus // Eprint Arxiv. arXiv. 2013. – P.1301;3557.
18. TensorFlow [Электронный ресурс]. – Режим доступа: <https://www.tensorflow.org/>. Torch/PyTorch. <https://pytorch.org/>. – Загл.с экрана.
19. Caffe [Электронный ресурс]. – Режим доступа: <http://caffe.berkeleyvision.org/>. – Загл.с экрана.
20. Theano [Электронный ресурс]. – Режим доступа: <http://deeplearning.net/software/theano/>. – Загл.с экрана.
21. **Krizhenvshky, A.** Imagenet classification with deep convolutional networks [Text] / A.Krizhenvshky, I.Sutskever, G.Hinton // In: Proc.conf.neural information processing systems (NIPS). – 2012. – 3–8 Dec. – P.1097–105.
22. **Szegedy, C.** Going deeper with convolutions [Text] / C.Szegedy, W.Liu, Y.Jia et al. // In: Proc.of the 2015 IEEE conf.on computer vision and pattern recognition.Boston, MA, USA, 7–12 June. – 2015. – P.1–9.
23. **Xie, S.** Aggregated residual transformations for deep neural networks [Text] / S.Xie, R.Girshick, P.Dollar et al. // arXiv. – 2017. – No.1611;05431.
24. **Huang, G.** Densely connected convolutional networks [Text] / G.Huang, Z.Lrj, L.V.D.Maaten et al. // In: IEEE conference on computer vision and pattern recognition. – 2017. – P.2261–9.

Бийбосунов Б.И.,
техника ғылымдарының докторы, профессор,
bbolotbek@mail.ru¹

Сабитов Б.Р.,
техника ғылымдарының кандидаты, профессор.
sabitovbr@kstu.kg¹

И. Арабаев атындағы Қырғыз мемлекеттік университеті,
720026, Бишкек, Раззаков к-си, 51а¹

САНДЫҚ АУЫЛ ШАРУАШЫЛЫҒЫ МӘСЕЛЕЛЕРИНЕ АРНАЛҒАН МАШИНАЛЫҚ ЖӘНЕ ТЕРЕҢ ОҚЫТУ ӘДІСТЕРІ

Аңдатпа. Бұл мақалада климаттың өзгеруінің әртүрлі экологиялық және аграрлық жүйелерге әсері қарастырылды. Зерттеу құралдары ретінде жасанды интеллекттің екі элементі - машиналық және терең оқыту таңдалды. Әртүрлі машиналық оқыту алгоритмдерін қолдана отырып, сзықтық емес түрлендірулерді білдіремін деректердегі жоғары деңгейлі абстракциялар модельденеді.

Өсімдік аурулары мен зиянкестерін анықтауга арналған нейрондық желілер машиналық және терең оқыту архитектураларын пайдаланатын веб-қосымшалар ретінде құрылды. Кескінді тану бағдарламалық жасақтамасы да жасалды. Машиналық және терең оқытуға негізделген өсімдік аурулары мен зиянкестерін анықтауга арналған архитектуралар тек академиялық құндылығы жоғары ғана емес, сонымен қатар ауылашаушылық қолданбалары үшін кең нарықтық әлеуетке ие.

Түйінди сөздер: машиналық оқыту, терең оқыту, ауыл шаруашылығы, жасанды интеллект, нейрондық желілер, өсімдік аурулары.

Biybosunov B.I.,
Doctor of Technical Sciences, Professor,
bbolotbek@mail.ru¹

Sabitov B.R.,
Candidate of Technical Sciences, Professor,
sabitovbr@kstu.kg¹

*Kyrgyz State University named after. I. Arabaeva,
720026, Bishkek, Razzakova street, 51a¹*

MACHINE AND DEEP LEARNING METHODS FOR DIGITAL AGRICULTURE PROBLEMS

Abstract. This paper examines the impact of climate change on various ecological and agricultural systems. Machine and deep learning, both elements of artificial intelligence, were chosen as the research tools. Using a variety of machine learning algorithms, high-level abstractions in data, representing nonlinear transformations, are modeled. Neural networks for detecting plant diseases and pests have been built as web applications using machine and deep learning architectures. Image recognition software has also been developed. Architectures built for detecting plant diseases and pests, based on machine and deep learning, are not only of great academic value but also have broad market potential for agricultural applications.

Keywords: *machine learning, deep learning, agriculture, artificial intelligence, neural networks, plant diseases.*