

Н.К. Мукажанов¹, Ж.М. Алибиева¹, М. Тұрдалыұлы^{1,2}, Д.Р. Рашидинов^{3*},
Н.Т. Исимов²

¹ Satbayev University, Алматы қ., Қазақстан

² Халықаралық инженерлік-технологиялық университеті, Алматы қ., Қазақстан

³ Халықаралық ақпараттық технологиялар университеті, Алматы қ., Қазақстан

*e-mail: damir.dmr88@gmail.com

ТЕРЕҢ ОҚЫТУДЫ ПАЙДАЛАНА ОТЫРЫП ӨСІМДІКТЕР АУРУЛАРЫН АНЫҚТАУ

Аңдатпа

Зерттеудің негізгі мақсаты, әлемде азық-түлікпен қамтамасыз етудегі шешуші рөл атқаратын өсімдіктердің ауруларын машиналық оқыту және терең оқыту сияқты озық технологияларының көмегімен ерте анықтау болып табылады. Бұл мақалада өсімдік ауруларын анықтау үшін машиналық оқыту мен терең оқыту әдістерін қолданудың соңғы жетістіктері қарастырылған. Зерттеу барысында, 2012-2023 жылдар аралығындағы ғылыми басылымдарға баса назар аударылып, жүргізілген тәжірибелердің дәлдігі мен тиімділігін арттыру үшін, ұсынылған әдістерді қолданудың тиімділігі көрсетілген. Ұсынылған жұмыста, деректердің қолжетімділігіне, бейне сапасына, сондай-ақ дені сау және ауру өсімдіктер арасындағы дифференциацияға қатысты мәселелері секілді, өсімдіктер ауруларын анықтау үшін, машиналық оқыту және терең оқыту алгоритмдері пайдаланылды. Өсімдік ауруларын анықтау бойынша нейрондық желілерін оқыту алма, картоп және қызанақ жемістері бойынша жинақталған деректерге жүргізілді. Зерттеу нәтижесінде, 11 қабатты нейрондық желі 98% дәлдік көрсетті.

Түйін сөздер: машиналық оқыту, терең оқыту, нейрондық желі, жасанды интеллект, орамалы нейрондық желі, кескіндерді классификациялау

Н.К. Мукажанов¹, Ж.М. Алибиева¹, М. Турдалыұлы^{1,2}, Д.Р. Рашидинов³, Н.Т. Исимов²

¹ Satbayev University, Алматы, Казахстан

² Международный инженерно-технологический университет, г. Алматы, Казахстан,

³ Международный университет информационных технологий, г. Алматы, Казахстан,

ВЫЯВЛЕНИЕ БОЛЕЗНЕЙ РАСТЕНИЙ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОГО ОБУЧЕНИЯ

Аннотация

Основная цель исследования – использовать передовые технологии, такие как машинное обучение и глубокое обучение, для раннего выявления заболеваний растений, которые играют решающую роль в обеспечении продовольственной безопасности. В статье рассматриваются последние достижения в использовании методов машинного обучения и глубокого обучения для обнаружения болезней растений. Анализ охватывает научные публикации, опубликованные в период с 2012 по 2023 год, подтверждающие эффективность применения данных методов для повышения точности и эффективности экспериментов. В представленной работе алгоритмы машинного обучения и глубокого обучения использовались для обнаружения болезней растений, а также для решения проблем, связанных с нехваткой данных, качеством изображений и точной классификацией здоровых и больных растений. Обучение нейронных сетей для обнаружения болезней растений осуществлялось на данных, содержащих изображения плодов яблок, картофеля и томатов. В результате экспериментов 11-слойная нейронная сеть достигла точности 98%.

Ключевые слова: машинное обучение, глубокое обучение, нейронная сеть, искусственный интеллект, сверточная нейронная сеть, классификация изображений.

N.K. Mukajanov¹, Z.M. Alibiyeva¹, M. Turdalyuly^{1,2}, D.R. Rashidinov³, N.T. Issimov²

¹ Satbayev University, Almaty, Kazakhstan

² International Engineering and Technological University, Almaty, Kazakhstan

³ International University of Information Technologies, Almaty, Kazakhstan

DETECTION OF PLANT DISEASES USING DEEP LEARNING

Abstract

The main goal of the study is to utilize advanced technologies, such as machine learning and deep learning, for the early detection of plant diseases, which play a crucial role in ensuring food security. The article examines the latest advancements in the use of machine learning and deep learning methods for detecting plant diseases. The analysis covers scientific publications published between 2012 and 2023, confirming the effectiveness of these methods in improving the accuracy and efficiency of experiments. In this study, machine learning and deep learning algorithms were used to detect plant diseases, as well as to address challenges related to data scarcity, image quality, and the accurate classification of healthy and diseased plants. The training of neural networks for plant disease detection was conducted using datasets containing images of apples, potatoes, and tomatoes. As a result of the experiments, the 11-layer neural network achieved an accuracy of 98%.

Keywords: machine learning, deep learning, neural network, artificial intelligence, convolutional neural network, image classification

Негізгі ережелер

Ауыл шаруашылығы климаттың өзгеруі, халық санының өсуі және азық-түлік қауіпсіздігін қамтамасыз ету қажеттігі сияқты күрделі мәселелерге тап болуда. Өсімдіктер ауруларын ерте кезеңде анықтау мен олардың алдын алу ауыл шаруашылығының тиімділігі үшін маңызды, алайда дәстүрлі әдістер жоғары дәлдікті әрдайым қамтамасыз ете алмайды. Терең оқыту, әсіресе орамалы нейронды желілер (CNN), өсімдіктер ауруларын анықтаудың автоматтандырылған және дәл шешімдерін ұсынады, бұл ауруларды уақтылы емдеу мен олардың таралуын болдырмауға мүмкіндік береді. Сонымен қатар, веб-платформаларды дамыту терең оқыту технологияларын фермерлер мен агрономдардың тәжірибесіне енгізуге көмектеседі. Бұл бағыттағы ғылыми-зерттеу жұмыстары өсімдіктердің жағдайын диагностикалау мен мониторингілеудің неғұрлым дәл және қолжетімді әдістерін әзірлеуге ықпал етеді.

Кіріспе

Табысты егіншіліктің басты аспектілерінің бірі өсімдіктерді сақтау және ауруларды уақтылы анықтау болып табылады. Өсімдік ауруларын диагностикалаудың дәстүрлі әдістері, мысалы, агрономдардың көзбен шолып қарауы, көбінесе, едәуір уақыт пен адами ресурстарды қажет етеді және әрдайым қажетті дәлдікті қамтамасыз ете бермейді. Бұл тұрғыда терең оқыту технологиялары диагностикалық дәлдікті автоматтандыру мен арттырудың инновациялық шешімдерін ұсынады [1,2]. Терең оқыту, атап айтқанда, орамалы нейронды желілер (CNN) бейнелерді жіктеу міндеттерінде жоғары тиімділік көрсетті. Бұл тәсілдер суреттердің күрделі ерекшеліктерін автоматты түрде шығарып, талдай алады, бұл оларды ауыл шаруашылығына қолдануға қолайлы етеді. Зерттеулер көрсеткендей, өсімдіктер ауруларын диагностикалау үшін терең оқытуды пайдалану ауруларды анықтаудың дәлдігі мен жылдамдығын едәуір арттыруға мүмкіндік береді, бұл өз кезегінде ауруларды уақтылы емдеуге және оның таралуының алдын алуға ықпал етеді [3,4]. Терең оқыту модельдерін оқыту мен сынаудың негізгі ресурстарының бірі әртүрлі аурулардан зардап шеккен әртүрлі өсімдіктердің бейнелерінің көптігін қамтитын PlantVille деректер жиынтығы болып табылады. Осы деректерге сүйене отырып, түрлі нейронды желі архитектуралары жасалып, сынақтан өтті, мысалы, VGG, AlexNet, ResNet, және Inception, олар ауруларды жіктеуде жоғары дәлдікті көрсетеді [5]. Сонымен қатар, веб-платформаларды дамыту терең оқыту технологияларын фермерлер мен агрономдардың күнделікті тәжірибесіне біріктіруге мүмкіндік береді. Мұндай

қосымшалар далалық жағдайдағы өсімдіктердің суреттерін түсіру үшін, содан кейін оларды нақты уақыт режимінде ауруды диагностикалау үшін өңдеу үшін пайдаланылуы мүмкін. Бұл өсімдіктердің жай-күйін бақылау процесін жеңілдетіп қана қоймай, оларды күту бойынша жедел шаралар қабылдауға мүмкіндік береді. Осылайша, өсімдіктердің ауруларын анықтау үшін терең оқыту әдістерін қолдану ауыл шаруашылығының тиімділігі мен тұрақтылығын айтарлықтай арттыруға мүмкіндік беретін перспективалы бағытты көрсетеді. Осы саладағы одан арғы ғылыми-зерттеу және тәжірибелік-конструкторлық әзірлемелер өсімдіктердің жағдайларын диагностикалау мен мониторингілеудің неғұрлым дәл және қолжетімді құралдарын жасауға ықпал ететін болады [6-8].

2015 жылы «Nature» журналында жарияланған авторлар Yann LeCun, Yoshua Bengio және Geoffrey Hinton «Deep learning» мақаласында [9] терең оқыту (DL) әдістеріне соның ішінде, орамалы нейронды желілерді (CNN), олардың архитектураларына, сондай-ақ олардың компьютерлік көру, сөйлеуді тану, ауыл шаруашылығы сияқты түрлі салалардағы кең қосымшаларына жан-жақты шолу жасаған. Авторлар нейронды желілердің дамуын және қарапайым модельдерден күрделі терең оқыту архитектураларына көшуді сипаттай отырып, тарихи контекстен басған. Олар көп қабатты перцептрондар бастап, қатенің кері таралу алгоритмдерінің тууы сияқты негізгі тұстарды талқылаған. Мақалада сондай-ақ терең оқыту архитектуралары сипатталған. Оның ішінде: CNN орамалы нейронды желілермен (CNN) бейнелерді торлы топологиямен өңдеу қарастырылған. Табысты CNN архитектураларының мысалдарына AlexNet пен VGG жатады. Рекуррентті нейронды желілер (RNN) мәтін және уақыт қатары сияқты тізбекті деректермен жұмыс істеуге арналған. Ұзақ қысқа мерзімді жад (LSTM) және қақпалы рекуррентті бірліктер (GRU) — RNN жойылған градиенттер мәселесін шешуге көмектесетін жақсартулар десек болады. Автокодерлер (Autoencoders) - бұл желіге берілетін деректерді неғұрлым сығуға, кодтауға, содан кейін оны кері декодтауға үйретілген. Деректерді генерациялау үшін, мысалы, вариациялық аутокодерлер (VAE) пайдаланылады. Тереңдетілген ықтималдылық моделдері, яғни Байес желілері мен вариациялық әдістер деректердегі күрделі тәуелділіктерді модельдеу үшін қолданылады. Авторлар нейронды желілерді оқыту әдістерін егжей-тегжейлі талқылайды, оның ішінде градиентті түсіруді және оның SGD (стохастикалық градиентті түсіру) және Adam нұсқаларын пайдалануды қарастырған. Сондай-ақ, модельдердегі өнімділікті арттыруға және қайта үйретуді алдын алуға көмектесетін қалыпқа келтіру және тұрақтыландыру әдістері талқыланды. Сонымен қатар авторлар зерттеудің болашақ бағыттарын, соның ішінде нейронды желі архитектурасын жетілдіруді, оқытудың жаңа алгоритмдерін әзірлеуді, модельдердің интерпретациясын арттыруды талқылаған. Сондай-ақ модельдік оқытуды жеделдету үшін неғұрлым қуатты және энергияға тиімді аппараттық құралдардың қажеттілігін айтқан. LeCun, Bengio және Hinton 2015 жылғы "Deep learning" мақаласы терең оқыту және оның қолданылуы мәселелерін түсінуге маңызды үлес қосқан. Ауыл шаруашылығы жағдайында өсімдік ауруларын диагностикалау үшін CNN-ді қолдану ауыл шаруашылығы практикасының өнімділігі мен тұрақтылығын арттыру үшін DL басымдылығын көрсеткен.

Зерттеу әдіснамасы

2012 жылы жарық көрген Алекс Крижевский, Илья Сутскевер мен Джеффри Хинтонның «ImageNet classification with deep convolutional neural networks» мақаласы [10], компьютерлік көру саласындағы революциялық зерттеу болып табылады. Ол AlexNet моделін сипаттайды, ол алғаш рет суреттерді үлкен ImageNet деректер жиынтығына жіктеу міндетінде терең орамалы нейронды желілердің (CNN) елеулі артықшылығын көрсетті. ImageNet деректер жиынтығынан алынған суреттерді жіктеуге қабілетті CNN, онда 1000 санатқа белгіленген 1,2 миллионнан астам сурет бар. Авторлар шешуге тырысқан басты мәселе осындай үлкен деректер жиынтығы бойынша тиімді үйреніп, машиналық оқытудың дәстүрлі әдістерін басып озатын архитектура құру болды. Бұл зерттеуде AlexNet архитектурасы 8 қабаттан: 5 орама қабат және 3 толықбайланысқан қабаттан тұрады. Архитектураның негізгі ерекшеліктері:

белсендіру функциялары ретінде ірі орамалы қабаттарды (11x11, 5x5) және RELU (Rectified Linear Unit) пайдалану, бұл дәстүрлі сигмоидты немесе гиперболалық тангенстермен салыстырғанда тезірек оқу процесін жүргізуге мүмкіндік беретіндігі. Pooling - көріністердің көлемін азайтатын және деректерді қорытатын max-pooling қабаттарын пайдалануы. Dropout - Артық толтырудың алдын алу үшін авторлар оқу кезінде нейрондарды кездейсоқ өшіріп тастау техникасын қолданғандығы, әрі модель архитектурасында есептеулерді жылдамдату және модельдің мөлшерін ұлғайту үшін екі GPU-ға бөліп, параллельді өңдеуді қолдануы. Авторлар жіктеу сапасын AlexNet ImageNet тест деректер жиынтығында 15,3% ең жоғарғы 5 категе қол жеткізді, бұл алдыңғы үздік нәтижелерге қарағанда айтарлықтай жақсы болды (26,2%). Үздік 1 қате 37,5% құрады. Осылайша Крижевский, Сутскевер, Хинтонның 2012 жылғы мақаласы компьютерлік көру және терең оқыту тарихындағы маңызды оқиғалардың бірі болды. Ол терең орама нейронды желілер үлкен деректер жиынтығындағы бейнелерді жіктеу тапсырмаларындағы дәстүрлі әдістерден едәуір асып кетуі мүмкін екенін көрсетті. AlexNet компьютерлік көру проблемаларын шешу тәсілдерін дамытып, жетілдіруді жалғастырып келе жатқан VGG, ResNet, Inception сияқты кейінгі архитектураларға жол ашты.


Mohanty, S. P., Hughes, D. P., & Salathé, M. 2016 жылы жарық көрген «Using deep learning for image-based plant disease detection» мақаласы [11] трансферттік оқытуды зерттеуге негізделген, олар суреттерді пайдалана отырып өсімдік ауруларын автоматты түрде диагностикалау үшін CNN-нің әр түрлі архитектураларының тиімділігін бағалауға зерттеу жүргізді. Зерттеу әр түрлі ауруларға шалдыққан өсімдіктердің суреттері бар PlantVillage деректер жиынтығына негізделді. PlantVillage деректер жиынтығына 38 кластың (аурулардың 26 класы және сау өсімдіктердің 12 класы) 54 мыңнан астам суреті кірді. Деректер модельдерді оқыту және бағалау үшін оқу-сынақ жинақтарына бөлінген. CNN архитектуралары ретінде бірінші 5 орамалы қабаттан және 3 толық байланысқан қабаттан тұратын AlexNet PlantVillage тест деректер жиынтығында 99,35% дәлдік көрсеткішіне қол жеткізгенін көрсеткен. Әрі екінші GoogleNet (Inception) концептуалды модульдерді қамтитын неғұрлым күрделі архитектурасы бар 22 қабаттан тұратын GoogleNet сол деректер жиынында 99,24% дәл болды. Нәтижелер алыну үшін моделдерді оқыту үшін стохастикалық градиентті түсіру және қалыпқа келтіру және тұрақтандыру техникалары қолданылды. Екі архитектура да өсімдіктер ауруларын жіктеуде жоғары дәлдік көрсетті, бұл диагностиканы автоматтандыруда терең оқыту әлеуетінің жоғары екендігін растайды. Одан кейінгі зерттеулерде Ферентинос К.П. Өзінің 2018 жылы келтірген «Deep learning models for plant disease detection and diagnosis» мақаласында [12] өсімдік ауруларын диагностикалау үшін CNN-нің әр түрлі архитектураларын салыстыруға бағытталған. AlexNet, VGG, ResNet және Inception сияқты архитектуралар PlantVillage деректер жиынтығында олардың дәлдігі мен тиімділігін бағалау үшін қайта қарастырды. Автордың зерттеулеріндегі деректер жиынтығы Моханти және т.б. зерттеуде қолданылғанға ұқсас, оның ішінде әр түрлі аурулары бар өсімдіктердің суреттері де бар болды. Автор CNN архитектураларына жеке-жеке түсініктемелер берді. AlexNet - классификацияда жоғары дәлдік көрсетті, бірақ жаңа архитектурадан кем түспеді. VGG - қарапайым және тиімді құрылымымен танымал 16-19 қабатты терең архитектура. ResNet - өте терең желілерді жаттықтыру үшін скиптік қосылымдарды пайдаланды. ResNet 99,53% дәлдік көрсеткішіне қол жеткізді. Нәтижелері кездейсоқ қиып алу, айналу, жарықтықтың өзгеруі сияқты деректерді толықтырудың алдыңғы қатарлы әдістері қолданды. ResNet және Inception ең жақсы нәтижелерді 99,53% дәлдікпен көрсетті, бұл олардың бейнелерді жіктеу тапсырмаларындағы артықшылығын растады. AlexNet пен VGG да жақсы нәтиже көрсетті, бірақ жаңа архитектурадан ұтылып қалды. Екі еңбек те өсімдік ауруларын диагностикалау үшін терең оқытуды қолдануда елеулі жетістіктерді көрсетеді. Ферентиностың [12] зерттеуі көрсеткендей, ResNet және Inception сияқты терең нейронды желілер бейнесін пайдалана отырып, өсімдіктер ауруларын диагностикалаудың қуатты құралдары болып табылады. Бұл модельдер ауруларды анықтаудың дәлдігі мен жылдамдығын едәуір арттыра алады, бұл ауыл шаруашылығы практикасын жетілдіруге және өнімділікті арттыруға ықпал етеді.

Өсімдіктердің ауруларын жапырақтарына қарап жіктеу әдістері бойынша қазіргі кезде жасалған басқа да авторлардың зерттеулерін қарастырып, талдағаннан кейін, біз барлық басқа қолданылатын әдістермен салыстырғанда терең оқыту әдістері дәлдігін табу тұрғысынан ең жақсы нәтижеге қол жеткізгенін байқадық. Алайда, терең оқыту әдістерінің ең маңызды шектеуі өсімдіктердің жапырақтары жайлы деректер жиынтығында жиі жетіспейтін үлкен оқыту деректеріне сүйену болып табылады. Өртүрлі өсімдік жапырақтары жайлы жіктеу осы зерттеуде енгізілген: ResNet және VGG архитектуралары жайлы болады. Бұрын айтып өткеніміздей, біздің зерттеуіміздегі бейнелерді талдау арқылы өсімдіктердің жапырақтары арқылы автоматтандырылған жіктеу тәсілі ұсынылды. Модель бастапқы бейнелерден алынған PlantVille деректерін пайдалана отырып оқытады. Пайда болған бейне VGG және Resnet ұсынылған модельдеріне енгізу ретінде пайдаланылады [13]. VGG қолданудағы басты артықшылық ол бір үлкен деңгейдің орнына бірнеше кіші бөліктерге бөлінген деңгейлердің болуы әрі осы бөліктердің шешім қабылдау фнкцияларының көмегімен жылдам бірге жиналуы болып табылады. Оның басты себебі сызықты емес белсенді қабаттардың көп болуында. Сонымен қатар, VGG архитектурасында кіші өлшемдегі орама сүзгілер қолданылады, ол өз кезегінде оқыту кезіндегі қайта оқуты ықтималдылығын азайтады. Сүзгілердің тиімді өлшемі – 3×3 , себебі одан кіші өлшемдер барлық берілген бағыттар бойынша көрші орналасқан пикселдер жайлы ақпараттарды қамти алмайды. Сәйкесінше, VGG моделі бейнелердің кеңістіктің сипаттамаларын талдау үшін ең қарапайым архитектуруны ұсынады. Сәйкесінше, VGG моделі бейненің кеңістіктік сипаттамасы үшін ең қарапайым архитектура болып табылады [14]. CNN-ге негізделген Resnet терең оқыту архитектурасы. Ол 18 қабаттан тұрады. Терең нейронды желі моделін қолдану, бейнелерді оқыту және бастапқы кезеңде тереңдік туралы ақпаратты алу үшін қолданылады. Кейіннен оқытылған нейронды желі моделі жаңа суреттерді анықтау немесе жіктеу үшін қолданылады. ResNet архитектурасы өте терең желілер құру мүмкіндігіне ие. Қабаттар үдерісі кезінде қабаттардың шамадан тыс көп болуынан пайда болады, әрі дәлдік деңгейі жылдам деректердің қосылыстарының есебінен төмендейді, бұл бірнеше қабатты айналып өту арқылы сәйкестікті тезірек картаға түсіруге мүмкіндік береді. ResNet бір 7×7 орама қабаттан, екі пуль қабатынан, сегіз қалдық бірліктен, бір толықбайланысқан қабаттан тұрады. Әрбір қалдық бірлік таңдалған деректер жиынтығынан кескіндеменің 10 түрлі түрін қамтитын толықбайланысқан қабатпен қатар екі 3×3 орама қабаттан тұрады. Біздің тәжірибемізде ең соңғы толықбайланысқан қабаттардағы Softmax функциясын және орама қабаттағы белсендіру функциясы ретінде Relu функциясын қамтитын ResNet моделін қолдандық. Бастапқы оқыту коэффициенті 0,0001 деңгейінде белгіленеді және ол оқыту барысында біртіндеп төмендейді [15].

Зерттеу нәтижелері

Бұл зерттеу жұмысында өсімдіктердің ауруларын анықтау үшін толық байланысытырылған (FCNN - fully connected neural network) және CCN нейрондық желілеріне зерттеулер жүргізілді. Аталған нейрондық желілер негізінен деректерді классификациялау үшін қолданылады. Өсімдік ауруларын анықтау бойынша толық байланысытырылған (fully connected neural network) және CCN нейрондық желілерін біріктіре отырып 20 астам архитектура әзірленіп, оларға тестер жасалынды. Олардың ішінде жоғары дәлдік көрсеткен екі нейрондық желі архитектурасын осы жұмыста ұсынатын боламыз. Сонымен қатар, зерттеу барысында алынған нәтижелерге сүйене отырып, сурттерді классификациялауда нейрондық желінің қандай архитектуралық құрылымы жақсырақ нәтиже бертіні туралы қысқаша ұсыныстар жасаймыз. Ұсынылатын бірінші нейрондық желі архитектурасы 4 конволюциялық блоктан және толық байланыстырылған блоктан тұрады. Әр бір конволюциялық блок 2 конволюция қабатынан және ішкі іріктеу операциясынан тұрады. Толық байланыстырылған блок 3 толық байланыстырылған нейрондық желі қабаттарынан тұрады. Бұл архитектура жалпы саны 11 нейрондық желі қабаттарынан құраған. Конволюциялық қабаттар суреттерден белгілерді шығару (feature extraction) үшін қолданылса, ал толық байланыстырылған 3 қабат

классификация үшін пайладанылды. Бұл нейрондық желі архитектурасы сұлбасы 1-суретте берілген.



Сурет 1. Өсімдік ауруларын классификациялаудың 11 қабатты нейрондық желі архитектурасы

Бірінші конволюциялық блок 2 конволюциялық нейрондық желі қабаттарынан және ішкі іріктеу операциясынан тұрады. Бірінші конволюциялық қабат кірісінде 256x256 өлшемді RGB кескінді қабылдайды, сонымен қатар онда 3x3 өлшемді 32 ядро берілген. Екінші конволюциялық қабат кіріс мәндерін алдыңғы қабаттан алады және 3x3 өлшемді 32 ядродан тұрады. Екі қабаттан кейін ішкі іріктеу операциясы (max-pooling, 2x2) орындалады. Ішкі іріктеуде пиксель блоктарының мәндерін біріктіру (қосу) арқылы кескінді 2 есе қысу (өлшемін азайту) процесі жасалады. Екінші конволюциялық блоктың әр бір қабаты 3x3 өлшемді 64 ядролардан тұрады және блок соңында ішкі іріктеу операциясы (max-pooling, 2x2) орындалады. Бұл блоктың бірінші қабаты (Conv2d-3) кіріс мәндерді алдыңғы блоктың ішкі іріктеуінен алады. Үшінші конволюциялық блоктың әр бір қабаты 3x3 өлшемді 128 ядролардан тұрады және блок соңында ішкі іріктеу операциясы (max-pooling, 2x2) орындалады. Бұл блоктың бірінші қабаты (Conv2d-5) кіріс мәндерді екінші блоктың ішкі іріктеуінен алады. Төртінші конволюциялық блоктың әр бір қабаты 3x3 өлшемді 256 ядролардан тұрады және блок соңында ішкі іріктеу операциясы (max-pooling, 2x2) орындалады. Бұл блоктың бірінші қабаты (Conv2d-7) кіріс мәндерді үшінші блоктың ішкі іріктеуінен алады. Жоғарыда берілген барлық конволюциялық қабаттарда «relu (rectified linear units)»-белсендіру (activation) функциясы қолданылды. Белсендіру функциясы-бұл қосқыштың нәтижесін кіріске қабылдайтын және өлшенген кірістердің қосындысын тапсырманы шешу тұрғысынан түсіндіруге болатын барабар шығысқа айналдыру үшін қандай да бір түрлендіруді орындайтын функция. Белсендіру функциясы қандайда бір мән қайтарады, егер x оң сан болса, кері жағдайда 0 мәнін қайтарады.

$$f(x) = \max(0, x) \quad (1)$$

Relu функциясы жақсы жуықтату құралы – кез келген функцияны ReLU комбинациясы арқылы жуықтатуға болады. Тағы бір артықшылығы - бұл функция нейрондар белсендендірген кезде сиректікті тудырады. Яғни, сигмоидтан және гиперболалық тангенстен айырмашылығы, барлық нейрондар белсендірілмейді, бұл есептеу күрделілігін төмендетеді. Бұл қасиет барлық теріс мәндердің жойылуынан туындайды. ReLU пайдалану сигма тәрізді және гиперболалық тангенспен салыстырғанда градиенттің түсуінің конвергенция жылдамдығын айтарлықтай арттырады. Конволюциялық нейрондық желілер арқылы алынған белгілерді кластарға бөлу үшін толық байланыстырылған қабатты қолдануымыз қажет. Бұл үшін желінің конволюциялық бөлігінен толық байланыстырылғанға көшу, көп өлшемді деректерді бір өлшемді векторға түрлендіретін, ешқандай параметрлері жоқ *Flatten()* қабатын


құру қажет. *Flatten()* қабатынан алынған вектор толық байланыстырылған (dense) блокқа беріледі. Толық байланыстырылған (dense) блок үш қабаттан тұрады. Бірінші және екінші қабатта толық байланыстырылған 4096 нейрон және «gelu» белсендіру функциясы берілген. Бұл екі қабат нейрондар арасында барынша толық байланыстарды қамтамасыз ету үшін енгізілді және эмпирикалық тексерулер арқылы тиімді нейрондар саны анықталынды. Келесі, үшінші толық байланыстырылған қабат 4 нейроннан және «softmax» белсендіру параметрлерінен тұрады. 4 нейрон классификацияланатын класстар саны, ал «softmax» белсендіру ықтималдық бойынша нейрондарды класстарға үлестіреді. Тест барысында, 11 қабатты нейрондық желі 98% дәлдік көрсетті (2-сурет). Бұл біз әзірлеп, тест жүргізген модельдердің ішіндегі ең жоғары көрсеткіш болады.

```
scores = model.evaluate(x_test, y_test, verbose=1)
```


49/49 [=====] - 25s 514ms/step - loss: 0.1029 - accuracy: 0.9807

Сурет 2. 11 қабатты нейрондық желі дәлдігі

Әзірленген нейрондық желіні 50 кезеңнен тұратын оқыту жүргізілді. Оқытуды бақылау бойынша графигі **5-суретте** берілген. Оқыту сапасын бақылау графигінде көрсетілгендей (**5 (а) суреті**), тексеру деректері бойынша дұрыс жауаптардың үлесі 16 кезеңнен кейін аса көтерілмейді және шамамен 36 кезеңнен кейін өзгеріссіз қалады. Бұл дегеніміз 36 кезеңнен кейін нейрондық желіні оқытудың қажеті жоқ. **5-сурет ә-да** қателесу бойынша бақылау графигінде а-суреттегідей 16-кезеңнен кейін аса қатты қателесу төмендемейді, ал 36 кезеңнен кейін қаталесу өзгеріссіз түзу сызықпен қалады.



а)




ә)

Сурет 3. Нейрондық желіні оқыту сапасын бақылау графигі

Ұсынылатын келесі нейрондық желі архитектурасы 12 қабаттан тұрады. Суреттерден белгілерді шығару үшін алдыңғы архитектураның құрылымы пайдаланылды, яғни 8 қабаты CNN нейрондық желі қабаттары, ал, классификация үшін нейрондық қабаттарға өзгеістер енгізілді. Толық байланыстырылған нейрондық желі қабаттар саны 4. Бастақы екі қабат 2048 нейроннан тұрса, 3-ші толық байланыстырылған нейрондық желі қабаты 512 нейроннан, ал соңғы қабат 4 нейроннан (классификация санына байланысты) тұрады. Бұл нейрондық желі архитектурасы сұлбасы 4-суретте берілген.

4-суретте берілген нейрондық желі архитектурасының соңғы толық байланыстырылған блогының бірінші екі қабатының (Dense-1 және Dense-2) нейрондар санын 2048 ден төмендету тест барысында дәлдік көрсеткішін төмендетенінін көрсетті. Сол себепті нейрондар саны 2048 болып алынды. Ал келесі, Dense-3 қабатта нейрондар саны 2048 ден 512 дейін дәлдік көрсеткішіне әсер етпеді, бірақ нейрондар саны 512-ден азайғанда дәлдіктің төмендеуі байқалды. Сол себепті 512 алынды, ал одан көп нейрондар саны параметр мәндерінің көбірек болуына байланысты есептеулер үшін тиімсіз. Соңғы, Dense-4 қабаттағы 4

классификацияланатын класстар саны және мұнда алдыңғы архитектурадағыдай белсендіру (activation) параметрінде «softmax» қолданылды.



Сурет 4. Өсімдік ауруларын классификациялаудың 12 қабатты нейрондық желі архитектурасы


Тест барысында, 12 қабатты нейрондық желі 96,59% дәлдік көрсетті (5-сурет). Бұл біз әзірлеп, тест жүргізген модельдердің ішіндегі екінші жақсы көрсеткіш болады.

```
scores = model.evaluate(x_test, y_test, verbose=1)
```

49/49 [=====] - 24s 494ms/step - loss: 0.2109 - accuracy: 0.9659


Сурет 5. 12 қабатты нейрондық желі дәлдігі.

Тестілеу мақатында және дұрыс оқыту кезеңін анықтау мақсатында 12 қабатты нейрондық желіге 40 кезеңнен тұратын оқыту жүргізілді. Оқытуды бақылау бойынша графигі 6-суретте берілген. Оқыту сапасын бақылау графигінде көрсетілгендей (а) 6-сурет), тексеру деректері бойынша дұрыс жауаптардың үлесі 17 кезеңнен кейін аса көтерілмейді. Бұл нейрондық желіні 17 кезеңнен кейін оқытудың қажеті жоқ. 6-сурет б-да қателесу бойынша бақылау графигінде а-суреттегідей 17-кезеңнен кейін аса қатты қателесу төмендемейді. Демек, нейрондық желінің бұл архитектурасына 17 оқыту кезеңі жеткілікті.



Сурет 6. 16 қабатты нейрондық желіні оқыту сапасын бақылау графигі

Өсімдік ауруларын анықтау бойынша нейрондық желілерін оқыту алма, картоп және қызанақ жемістері бойынша жинақталған деректерге жүргізілді. Оқытылған модельді қосымшаларда қолдану үшін .h5 форматындағы нұсқасы қалыптастырылды. Ұсынылып отырған нейрондық желіні пайдаланып өсімдік ауруын анықтау қосымшасының жұмыс алгоритмі 7-суретте берілген.



7 сурет. Өсімдік ауруларын анықтауға арналған нейрондық желінің қосымшада жұмыс істеу алгоритмі

Құрылған нейрондық желіні қосымшаларда қолдану үшін келесі әрекеттерді орындау қажет.

1. Суретті таңдау/жүктеу
2. Жүктелген сурет өлшемін 256x256 өлшемге өзгерту. Біздің нейрондық желі 256x256 өлшемді суреттер арқылы оқытылған.
3. Өлшемі келтірілген суреттерті сандық массив деректеріне түрлендіру. Модельді оқытар алдында барлық деректер жиыны сандық массив түрінде түрлендіріліп оқытылды.
4. Массив деректерін модельге беру. Массив деректері сандық массив форматында модельге беріледі.
5. Модельден болжамдарды алу. Алдын-ала оқытылып сақталған модель берілген сурет бойынша болжамды қайтарады. Алынған болжам қосымшаға беріледі.
6. Болжамдарды қосымшада ұсыну. Модельден алынған классификация деректері сандық түрде болғандықтан, оларды пайдаланушыларға ыңғайлы, қосымша талаптарына сәйкес түрге келтіру қажет.

Дискуссия

Қарастырылған ғылыми-зерттеу жұмысы, өсімдік ауруларын анықтауға арналған нейрондық желі архитектураларын құру және алынған нәтижелерін салыстыруды талдайды. Алынған нәтижелер көрсеткендей, 11 қабатты нейрондық желі 98% дәлдікке қол жеткізіп, ең жоғары нәтижені көрсетті, ал 12 қабатты желі 96,59% дәлдікпен екінші үздік модель ретінде анықталды. Бұл айырмашылықтар, зерттеу жұмысындағы, нейрондық желінің архитектурасы мен параметрлерін оңтайландырудың маңыздылығын көрсетеді. Сонымен қатар, зерттеу нәтижелері, модельдерді оқыту кезеңдерінің жеткілікті санын анықтаудың маңыздылығын көрсетті, себебі 36 рет оқытудан кейінгі кезеңдері 11 қабатты модельдің дәлдігін арттырмай, сонымен бірге, 12 қабатты модель үшін 17 кезең жеткілікті болды. Алынған нәтижелерді негізге ала отырып, болашақта модельді жетілдіру үшін деректерді көбейту мен нейрондық желінің құрылымын оңтайландыру және есептеу ресурстарын тиімді пайдалану бағытында қосымша зерттеулер жүргізу қажет.

Қорытынды

Өсімдік ауруларын анықтауға арналған нейронды желілер тапсырманың күрделілігіне және қолда бар деректерге байланысты таңдалады. Мақалада нейронды желілердің ең тиімді және жиі қолданылатын кейбір түрлері жайлы ақпараттар келтірілген. CNN - өсімдіктер ауруларын жіктеу сияқты бейнені талдауға байланысты тапсырмаларды орындау үшін ең танымал таңдау. Олар суреттерден кеңістіктік мүмкіндіктерді алу бойынша жақсы жұмыс атқарады.

Архитектуралардың сипаттамалары: LeNet: кескінді танудың қарапайым тапсырмаларына жақсы сай келетін алғашқы CNN-дердің бірі. AlexNet: Имидж жіктемесінде жоғары көрсеткіштер көрсету арқылы 2012 жылы ImageNet Challenge-ді жеңіп алған терең CNN. VGGNet: әр түрлі жіктеу тапсырмаларын жақсы орындайтын терең қабатты архитектура. ResNet (Қалдық желілер): градиенттерді түсіру проблемасынсыз өте терең желілерді салуға мүмкіндік беретін қалдық блоктарды қамтиды. Inception: ақпараттың әртүрлі деңгейлерін түсіру үшін әр қабаттағы әр түрлі өлшемдегі сүзгілер комбинациясын пайдаланады. EfficientNet: аз есептеу үстемесімен жоғары дәлдікке қол жеткізу үшін желі тереңдігін, енін және ажыратымдылығын теңестіретін оңтайландырылған архитектура.

Сонымен қатар деректерді алдын ала өңдеу және трансферттік оқыту сипаттамалары да келтірілген. Трансферлік оқыту ImageNet сияқты ірі деректер жиынтығында алдын ала дайындалған модельдерді (мысалы, ResNet, Inception) пайдалануға және оларды өсімдік ауруларын анықтау үшін нақты деректер бойынша қайта даярлауға мүмкіндік береді. Бұл модельді «нөлден» оқыту үшін қажетті уақыт пен ресурстарды айтарлықтай қысқартады. Ал суреттерді өңдеу және деректерді толықтыру оқыту жиынтығының алуан түрлілігін арттыру арқылы модельдің жалпылығын арттыруға көмектеседі. Бұл әсіресе деректер жиынтығы көлемімен шектелсе, пайдалы. Толықтыру әдістерінің: Кескіннің бұрылысы, Масштабтау, Көлденең және тік шағылысу, Жарықтық және қарама-қарсылық өзгерістері, Түсті өзгерту сияқты түрлерін қарыстырсақ болады. Сондай-ақ рекуррентті нейронды желілер RNN және LSTM дәстүрлі түрде тізбекті деректерді өңдеу үшін қолданылғанымен, олар өсімдік жағдайының уақытша үрдістерін ескеру қажет болғанда кескін немесе бейне уақыт сериясын талдау үшін CNN-мен үйлесімде пайдалы болуы мүмкін.

Пайдаланылған дереккөздердің тізімі

- [1] Agarwal, M., Singh, A., Arjaria, S., Sinha, A., Gupta, S. (2020). ToLeD: Tomato leaf disease detection using convolution neural network. *Proc. Comput. Sci.* 167 (2019), 293–301. <https://doi.org/10.1016/j.procs.2020.03.225>
- [2] Akbar, M., Ullah, M., Shah, B., Khan, R. U., Hussain, T., Ali, F., et al. (2022). An effective deep learning approach for the classification of bacteriosis in peach leave. *Front. Plant Sci.* 13. <https://doi.org/10.3389/fpls.2022.1064854>
- [3] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., et al. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J. Big Data* 8, 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- [4] Karthik, R., Hariharan, M., Anand, S., Mathikshara, P., Johnson, A., Menaka, R. (2020). Attention embedded residual CNN for disease detection in tomato leaves. *Appl. Soft Comput.* 86, 105933. <https://doi.org/10.1016/j.asoc.2019.105933>
- [5] Hughes, D.P., & 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. *ArXiv*, abs/1511.08060. <https://doi.org/10.48550/arXiv.1511.08060>
- [6] Deng, R., Tao, M., Xing, H., Yang, X., Liu, C., Liao, K., et al. (2021). Automatic diagnosis of rice diseases using deep learning. *Front. Plant Sci.* 12, 701038. <https://doi.org/10.3389/fpls.2021.701038>
- [7] Savla, D., Dhaka, V.S., Rani, G., Oza, M. (2022). Apple Leaf Disease Detection and Classification Using CNN Models. In: Iyer, B., Crick, T., Peng, S.L. (eds) *Applied Computational Technologies. ICCET 2022. Smart Innovation, Systems and Technologies*, vol 303. Springer, Singapore. https://doi.org/10.1007/978-981-19-2719-5_26
- [8] Ferentinos, K.P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- [9] Brahimi, M., Boukhalfa, K. and Moussaoui, A. (2017) Deep Learning for Tomato Diseases: Classification and Symptoms Visualization. *Applied Artificial Intelligence*, 31, 299–315. <https://doi.org/10.1080/08839514.2017.1315516>

- [10] ImageNet classification with deep convolutional neural networks. Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. *Authors Info & Claims. Communications of the ACM*, Volume 60, Issue 6, Pages 84 – 90. <https://doi.org/10.1145/3065386>
- [11] Mohanty, S.P., Hughes, D.P. and Salathe, M. (2016) Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7, 1419-1419. <https://doi.org/10.3389/fpls.2016.01419>
- [12] Ferentinos, K.P. (2018) Deep Learning Models for Plant Disease Detection and Diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. <https://doi.org/10.1016/j.compag.2018.01.009>
- [13] A. Victor Ikechukwu, S. Murali, R. Deepu, R.C. Shivamurthy. ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images. *Global Transitions Proceedings*. Volume 2, Issue 2, November 2021, Pages 375-381. <https://doi.org/10.1016/j.gltp.2021.08.027>
- [14]. K. Simonyan, A. Zisserman. Very deep convolutional networks for large-scale image recognition. 3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc (2015), pp. 1-14. <https://doi.org/10.48550/arXiv.1409.1556>
- [15] Mohameth, F. , Bingcai, C. and Sada, K. (2020) Plant Disease Detection with Deep Learning and Feature Extraction Using Plant Village. *Journal of Computer and Communications*, 8, 10-22. <https://doi.org/10.4236/jcc.2020.86002>

References

- [1] Agarwal, M., Singh, A., Arjaria, S., Sinha, A., Gupta, S. (2020). ToLeD: Tomato leaf disease detection using convolution neural network. *Proc. Comput. Sci.* 167 (2019), 293–301. <https://doi.org/10.1016/j.procs.2020.03.225>
- [2] Akbar, M., Ullah, M., Shah, B., Khan, R. U., Hussain, T., Ali, F., et al. (2022). An effective deep learning approach for the classification of bacteriosis in peach leave. *Front. Plant Sci.* 13. <https://doi.org/10.3389/fpls.2022.1064854>
- [3] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., et al. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J. Big Data* 8, 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- [4] Karthik, R., Hariharan, M., Anand, S., Mathikshara, P., Johnson, A., Menaka, R. (2020). Attention embedded residual CNN for disease detection in tomato leaves. *Appl. Soft Comput.* 86, 105933. <https://doi.org/10.1016/j.asoc.2019.105933>
- [5] Hughes, D.P., & 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. *ArXiv*, abs/1511.08060. <https://doi.org/10.48550/arXiv.1511.08060>
- [6] Deng, R., Tao, M., Xing, H., Yang, X., Liu, C., Liao, K., et al. (2021). Automatic diagnosis of rice diseases using deep learning. *Front. Plant Sci.* 12, 701038. <https://doi.org/10.3389/fpls.2021.701038>
- [7] Savla, D., Dhaka, V.S., Rani, G., Oza, M. (2022). Apple Leaf Disease Detection and Classification Using CNN Models. In: Iyer, B., Crick, T., Peng, S.L. (eds) *Applied Computational Technologies. ICCET 2022. Smart Innovation, Systems and Technologies*, vol 303. Springer, Singapore. https://doi.org/10.1007/978-981-19-2719-5_26
- [8] Ferentinos, K.P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. <https://doi.org/10.1016/j.compag.2018.01.009>
- [9] Brahimi, M., Boukhalfa, K. and Moussaoui, A. (2017) Deep Learning for Tomato Diseases: Classification and Symptoms Visualization. *Applied Artificial Intelligence*, 31, 299-315. <https://doi.org/10.1080/08839514.2017.1315516>
- [10] ImageNet classification with deep convolutional neural networks. Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. *Authors Info & Claims. Communications of the ACM*, Volume 60, Issue 6, Pages 84 – 90. <https://doi.org/10.1145/3065386>
- [11] Mohanty, S.P., Hughes, D.P. and Salathe, M. (2016) Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7, 1419-1419. <https://doi.org/10.3389/fpls.2016.01419>
- [12] Ferentinos, K.P. (2018) Deep Learning Models for Plant Disease Detection and Diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. <https://doi.org/10.1016/j.compag.2018.01.009>
- [13] A. Victor Ikechukwu, S. Murali, R. Deepu, R.C. Shivamurthy. ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images.

Global Transitions Proceedings. Volume 2, Issue 2, November 2021, Pages 375-381.
<https://doi.org/10.1016/j.gltp.2021.08.027>

[14]. K. Simonyan, A. Zisserman. Very deep convolutional networks for large-scale image recognition. 3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc (2015), pp. 1-14.
<https://doi.org/10.48550/arXiv.1409.1556>

[15] Mohameth, F. , Bingcai, C. and Sada, K. (2020) Plant Disease Detection with Deep Learning and Feature Extraction Using Plant Village. *Journal of Computer and Communications*, 8, 10-22.
<https://doi.org/10.4236/jcc.2020.86002>