

М.Ж. Сақыпбекова¹ , М.К. Солтангельдинова^{1*} 

¹Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

* e-mail: msoltangeldynova@gmail.com

ӨСІМДІК АУРУЛАРЫН ТАНУДА ҚОЛДАНЫЛАТЫН БЕС ТЕРЕҢ ОҚЫТУ ӘДІСТЕРІНЕ ШОЛУ

Аңдатпа

Терең оқыту саласындағы соңғы жетістіктер кескіндер негізінде өсімдік ауруларын тану әдістерін айтарлықтай жетілдіруге мүмкіндік берді. Алайда мұндай жүйелердің көпшілігі әлі де зертханалық жағдайда жасалып, сыналуда, бұл оларды нақты ауыл шаруашылығында тікелей қолдануды қиындатады. Бұл шолуда 2020-2025 жылдары жарияланған 43 ғылыми жұмыс қарастырылып, онда өсімдік ауруларын тануға арналған DL әдістері қолданылған. Жалпылама шолулардан айырмашылығы, мұнда мақалалар міндеттерге (мысалы, классификация немесе сегментация) емес, нақты архитектураларға бағытталған тәсілмен талданады. YOLO, Faster R-CNN, UNet, CNN+ViT гибридтері, сондай-ақ жеңіл MobileNet және EfficientNet модельдері қарастырылады. Әрқайсысы құрылым, жылдамдық, дәлдік және далалық жағдайға жақын ортадағы жұмыс істеу қабілеті тұрғысынан бағаланды. Жұмыстың басты мақсаттарының бірі – тек дәлдігі жоғары ғана емес, сонымен қатар практикалық тұрғыдан қолайлы модельдерді айқындау: нақты уақыт режимінде, ресурстары шектеулі құрылғыларда және далада түсірілген кескіндермен жұмыс істей алу. Бұл шолу аграрлық жасанды интеллект жүйелерін әзірлейтін зерттеушілер мен инженерлер үшін пайдалы болып табылады.

Түйін сөздер: өсімдік ауруларын тану, терең оқыту әдістері, YOLO, Faster R-CNN, гибридті және жеңіл модельдер, жағдайды мониторингілеу.

М.Ж.Сақыпбекова¹, М.К.Солтангельдинова¹

¹Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан
**ОБЗОР ПЯТИ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ, ПРИМЕНИМЫХ ДЛЯ
РАСПОЗНАВАНИЯ БОЛЕЗНЕЙ РАСТЕНИЙ**

Аннотация

Недавние успехи в области глубокого обучения позволили значительно улучшить методы распознавания заболеваний растений на основе изображений. Однако многие из таких систем всё ещё разрабатываются и тестируются в лабораторных условиях, что затрудняет их прямое применение в настоящем сельском хозяйстве. В этом обзоре рассматриваются 43 научные работы, опубликованные в 2020-2025 гг., в которых применяются методы DL для распознавания заболеваний растений. В отличие от обобщённых обзоров, где статьи делят по задачам (например, классификация или сегментация), здесь применяется подход, ориентированный на конкретные архитектуры. Рассматриваются такие методы, как YOLO, Faster R-CNN, UNet, гибриды CNN+ViT и лёгкие модели MobileNet и EfficientNet. Каждая из них оценивается с точки зрения структуры, скорости, точности и поведения в условиях, приближенных к полевым. Одна из целей работы – выделить те модели, которые не только точны, но и практичны: работают в реальном времени, на ограниченных устройствах и с изображениями из поля. Это делает обзор полезным для исследователей и инженеров, создающих аграрные ИИ-системы

Ключевые слова: распознавание болезней растений, методы глубокого обучения, YOLO, Faster R-CNN, гибридные и легковесные модели, мониторинг состояния.

M.Zh. Sakypbekova¹, M.K. Soltangeldinova¹

¹Al-Farabi Kazakh National University, Almaty, Kazakhstan

A COMPARATIVE REVIEW OF FIVE DEEP LEARNING METHODS FOR PLANT DISEASE RECOGNITION

Abstract

Recent advances in deep learning have significantly improved image-based methods for plant disease recognition. However, many of these systems are still developed and tested under laboratory settings, which hinders their direct applicability in real-world agriculture. This review examines 43 scientific studies published between 2020 and 2025 that applied DL methods for plant disease recognition. Unlike generalized surveys that classify articles by tasks (e.g., classification or segmentation), this work adopts an architecture-oriented approach. The methods under consideration include YOLO, Faster R-CNN, U-Net, CNN+ViT hybrids, and lightweight models such as MobileNet and EfficientNet. Each architecture is evaluated in terms of structure, speed, accuracy, and performance under conditions close to field environments. One of the key objectives of this work is to identify models that are not only accurate but also practical: capable of operating in real time, on resource-constrained devices, and with images directly obtained from the field. This makes the review valuable for researchers and engineers developing AI systems for agriculture.

Keywords: plant disease recognition, deep learning methods, YOLO, Faster R-CNN, hybrid and lightweight models, condition monitoring

Кіріспе

Ауыл шаруашылығы азық-түлік қауіпсіздігінің негізгі саласы болып қала береді, дегенмен өсімдік аурулары, зиянкестер және климаттың өзгеруі дақылдардың өнімділігіне қауіп төндіруде. FAO мәліметтері бойынша, аурулар мен зиянкестерден болатын шығындар жыл сайын 20-40%-ға жетеді, бұл уақтылы диагностикалау қажеттілігін көрсетеді [1].

Ауруды ерте анықтау қиын: сыртқы белгілер өсу кезеңіне, ауа райы жағдайларына және кескін сапасына байланысты өзгеріп тұрады. Дәстүрлі визуалды тексеру жоғары шеберлікті қажет етеді және субъективті нәтижелер береді, бұл компьютерлік көру мен жасанды интеллектке негізделген автоматтандырылған әдістерге қызығушылықтың артуына әкеледі [2,3].

Терең оқыту (ТО) әдістерінің дамуы өсімдік ауруларын автоматты түрде жіктеу, анықтау және сегменттеу үшін жаңа мүмкіндіктер ашты [4]. Ең кең таралғандары CNN архитектуралары (YOLO, Faster R-CNN, U-Net), сондай-ақ Vision Transformer негізіндегі гибриді модельдер. EfficientNet және MobileNet сияқты жеңіл желілер мұндай жүйелерді практикалық ауыл шаруашылығында енгізуге мүмкіндік береді [5]. Дегенмен, көптеген модельдер PlantVillage сияқты зертханалық деректер жиынтықтарында оқытылады және тексеріледі, онда кескіндер бақыланатын жағдайларда жиналды: біркелкі фон, біркелкі жарықтандыру және шу мен табиғи ауытқулардың болмауы. Зерттеулер көрсеткендей, мұндай модельдер нақты далалық кескіндерге қолданылған кезде көбінесе дәлдіктің төмендеуін көрсетеді. Көлеңкелер, жартылай жабылған жапырақтар, күрделі фондар немесе әртүрлі өсу сатылары болған кезде болжамдардың сенімділігі төмендейді.

Сонымен қатар, бұрынғы шолу мақалалары негізінен архитектура бойынша емес, тапсырма түрі бойынша (мысалы, жіктеу, сегменттеу) ұйымдастырылған, бұл нақты техникалық жағдайлар үшін оңтайлы модельдерді таңдауды қиындатады. Нақты әлемдегі жұмыс уақыты, далалық жағдайларға беріктік, ресурстарды тұтыну және көп сатылы мониторинг және диагностикалық жүйелерге қолданылуы сияқты сипаттамалар да сирек талданады. Бұл шолу мақаласы бұл олқылықты келесі ұсыныстар арқылы толтырады:

- Бес танымал әдістің құрылымдық талдауы: YOLO, Faster R-CNN, U-Net, CNN+ViT гибридітері және EfficientNet/MobileNet;

- Әрбір архитектураны дәлдікке, жылдамдыққа, күрделілікке және далалық жағдайларға сәйкестігіне негізделген бағалау;

- Қолданылған деректер жиынтығы мен зерттеу жағдайларын шолу;

- Практикалық ауылшаруашылық жүйелерінде енгізу үшін қай әдістердің ең перспективалы екендігі туралы қорытындылар.

Зерттеу әдіснамасы

Бұл шолудың мақсаты – өсімдік ауруларын танудың терең оқыту әдістерінің құрылымдық және салыстырмалы талдауын ұсыну, әсіресе олардың ашық дала жағдайында қолданылуына баса назар аудару. Осы мақсатқа жету үшін біз келесі стратегияны қолдана отырып, тиісті ғылыми басылымдарды жүйелі түрде таңдадық.

Іздеу стратегиясы: Scopus, IEEE Xplore, SpringerLink, ScienceDirect және Google Scholar сияқты ірі ғылыми дерекқорларда әдебиеттерді іздеу жүргізілді. Келесі кілт сөздер қолданылды: өсімдік ауруларын анықтау, терең оқыту, дала жағдайлары, YOLO, Faster R-CNN, CNN+ViT гибриді, MobileNet, дақылдарды бақылау. Жариялау кезеңі 2020 жылдан 2025 жылға дейін белгіленді, бұл бізге терең оқыту архитектурасындағы соңғы жетістіктерді және онымен байланысты қиындықтарды көрсететін тиісті зерттеулерді жинауға мүмкіндік берді. Біз тек ғылыми журналдардан алынған сарапшылар бағалаған мақалаларды және жоғары сапалы конференция материалдарын қарастырдық.

Қосу және алып тастау критерийлері. Қосу критерийлері:

- Мақалада өсімдік ауруларын тану үшін терең оқыту әдісі (мысалы, YOLO, Faster R-CNN, UNet, CNN+ViT, MobileNet/EfficientNet) ұсынылды.

- Мақалада өсімдік жапырақтарының нақты суреттері бойынша нәтижелер ұсынылды.

- Басылымда жеткілікті техникалық ақпарат болды: модель архитектурасы, пайдаланылған деректер жиынтығы, дәлдік көрсеткіштері.

- Суреттер далалық жағдайларда алынған немесе модельдің нақты ауыл шаруашылығына қолданылуы талқыланған зерттеулерге басымдық берілді.

Шығару критерийлері:

- Тек дәстүрлі машиналық оқыту әдістерін (мысалы, SVM, KNN) қолданған мақалалар.

- Эксперименттік бөлімсіз немесе негізгі бағалау көрсеткіштерін көрсетпей жарияланымдар.

- Далалық органның күрделілігін ескермей, тек зертханалық жағдайларға бағытталған жұмыстар.

Басылымдарды іріктеу және топтастыру. Бастапқы жиынтықтан біз 186 мақаланы талдап, қосу критерийлеріне толық сәйкес келетін 43 басылымды таңдадық. Таңдалған зерттеулер тапсырма түрі бойынша емес, архитектура түрі бойынша топтастырылды (жіктеу, сегменттеу және т.б.), бұл бізге нақты модельдердің өнімділігін дәлірек салыстыруға мүмкіндік берді:

- YOLO (You Only Look Once) – 13 мақала

- Faster R-CNN – 8 мақала

- U-Net – 8 мақала

- Hybrid CNN + Vision Transformer (ViT) – 7 мақала

- Жеңіл модельдер (MobileNet, EfficientNet) – 7 мақала

Әр топ үшін келесі параметрлерді талданды: модель архитектурасы, пайдаланылған деректер жиынтығы, класстар саны, дақыл/өсімдік түрі, түсіру жағдайлары (зертханалық немесе далалық), сондай-ақ негізгі көрсеткіштер (дәлдік, қорытынды уақыты және т.б.).

Зерттеу нәтижелер

Бұл бөлімнің мақсаты - өсімдік ауруларын тану үшін қолданылатын ең танымал бес терең оқыту архитектурасының салыстырмалы талдауын жүргізу: YOLO, Faster R-CNN, U-Net, CNN+ViT гибридтері және жеңіл MobileNet және EfficientNet модельдері. Таңдалған 43 басылымды талдау негізінде біз әр архитектураны бірнеше параметрлер бойынша бағаладық: пайдаланылған деректер жиынтығының түрі, зерттеу жағдайлары (далалық немесе зертханалық), жіктеу/анықтау дәлдігі, қорытынды жылдамдығы, шуылға төзімділік және

нақты ауылшаруашылық жағдайларында енгізуге жарамдылығы. Бұл тәсіл бізге әрбір модель тобының күшті және әлсіз жақтарын анықтауға ғана емес, сонымен қатар ашық егістіктерде жұмыс істейтін интеллектуалды мониторинг жүйелерін одан әрі дамытудың ең перспективалы бағыттарын анықтауға мүмкіндік берді.

YOLO моделін талдау

Ең көрнекі зерттеулердің бірі – [6], онда YOLOv4 моделі PlantVillage деректер жиынтығынан 14 дақылда 99,99% дәлдікке және $F1 \approx 0,99$ -ға қол жеткізді, бұл зертханалық жағдайларда жоғары әлеуетті көрсетті. Дегенмен, бастапқы кескіндердің біртектілігіне байланысты мұндай нәтижелерді далалық жағдайда қайталау мүмкін болмауы мүмкін. Нақты әлемдегі ауыл шаруашылығындағы қолданбалы мәселелерді шешу үшін [7] CBAM және BiFPN модульдерімен YOLOv5-тің жақсартылған нұсқасын қолданды. Модель дәлдік бойынша 96,4% және $mAP = 93,8\%$ деңгейіне жетті, бұл дәлдік пен есептеу тиімділігі арасындағы тамаша тепе-теңдікті көрсетеді.

1-кестеде YOLO алгоритмінің әртүрлі нұсқаларын қолдана отырып, өсімдік ауруларын анықтаудың заманауи тәсілдерінің салыстырмалы талдауы келтірілген.

Кесте 1. YOLO әдісі бойынша салыстырмалы талдау

№	Мақала	Әдіс	Дақыл түрі	Нәтиже
1	Rahman, M. A., Akhter, A., Rahman, M. M.	YOLOv4	14 дақыл түрi (PlantVillage)	Accuracy = 99.99%, F1 ≈ 0.99
2	Liu, Y., Zhang, Q., Chen, L.	YOLOv5 + CBAM + BiFPN	Қызанақ	Precision = 96.4%, mAP = 93.8%
3	Li, X., Wang, Y., Zhang, L	YOLOv4-tiny (модиф.)	Алма	mAP@0.5 = 97.7%, FPS = 62.4
4	Alam, R., Hossain, M., Kabir, M.	YOLOv5s	Бидай	Барлық өсу кезеңдерінде жоғары дәлдік
5	Chen, H., Yu, D., Li, W.	YOLOv8s (модиф.)	Бидай	Жоғары дәлдік
6	Wang, J., Xu, T., & Guo, S.	GVC-YOLO	Мақта	mAP = 91.8%, F1 = 94.7%
7	Alsheikh, M., Ali, A., Ahmed, F.	YOLOv5 (жақсартылған)	Өсімдіктер	mAP ≈ 93–95%
8	Patil, D. R., Kale, A., Shinde, P.	YOLOv5 + салыстыр.	Қызанақ, қияр т.б.	Жоғары дәлдік
9	Zhang, Y., Feng, X., Zhou, H.	YOLOv5	Күріш	Precision: 94.3%, Recall: 89.6%, mAP: 93.5%
10	Basha, M., Babu, M.	Improved YOLOv3	Қызанақ	F1-score: 94.77%, AP: 91.81%
11	Mahmood, T., Iqbal, A., Shah, A.	YOLOv8 optimization	Бірнеше дақыл түрлері	Жоғары дәлдік
12	Alsheikh, M., Rahman, A., Ahmed, F.	YOLOv3 YOLOv4	Шабдалы, құлпынай	YOLOv3: 97% accuracy, mAP 92%. YOLOv4: 98% accuracy, mAP 98%.
13	Khan, N., Tariq, U., Azam, F.	YOLOv8	Бидай	precision = 0.79, recall = 0.74, F1 = 0.77, average precision = 0.35

Зерттеулер қызанақ пен бидайдан, күріш пен алмаға дейінгі дақылдардың кең ауқымын қамтиды, сондай-ақ базалық және жақсартылған YOLO модельдерін қолдана отырып, жоғары дәлдікті (accuracy, mAP, F1-score) көрсеткішті көрсетеді. Нақты әлемдегі далалық жағдайларда өнімділікті жақсартатын модель модификацияларына (мысалы, CBAM, BiFPN, GhostConv) ерекше назар аударылады.

Өсімдік ауруларын анықтауға арналған Faster R-CNN әдістеріне талдау

2-кестеде ауруды диагностикалауға Faster R-CNN әртүрлі модификацияларын қолданған сегіз зерттеу көрсетілген. Зерттеулер зертханалық және далалық жағдайларды, тіпті бейнедегі ағынды диагностикалық тапсырмаларды да қамтиды.

[8]-де қызанақ жапырағы ауруын анықтау үшін эвристикалық алгоритмдерді (Fruit Fly және Simulated Cutting) Faster R-CNN-мен біріктіретін гибриді тәсіл ұсынылды. Авторлар 98,3% дәлдікке және 98,0% дәлдікке қол жеткізді, бұл әдісті ерте анықтау жүйелері үшін ерекше қызықты етеді. [9]-да Faster R-CNN және ResNet50 көмегімен күріш ауруын диагностикалаудың нақты уақыт режиміндегі тәсілі ұсынылды. Модель $\approx 98-99\%$ дәлдікке қол жеткізді, бұл оның далалық жағдайларда сенімділігін растайды.

Кесте 2. Faster-R CNN әдісін қолданып салыстырмалы талдау

№	Мақала	Әдіс	Дақыл түрі	Нәтиже
1	Du et al.	Faster R-CNN + ResNet50, soft-NMS	Кукуруз	AP $\approx 63\%$
2	Gangadevi et al	Faster R-CNN + эвристика	Қызанақ	Accuracy = 98.3%, Precision = 98.0%
3	De Silva & Brown	Faster R-CNN vs YOLOv4	Бидай	AP = 48.9%
4	Dawod & Dobre	Faster R-CNN	Күнбағыс	Accuracy = 88%,
5	Gong & Zhang	Faster R-CNN + Res2Net + FPN + RoIAlign	Алмас	AP ₅₀ = 91.3%, FPS = 12.2
6	Bari et al.	Faster R-CNN + ResNet50	Күріш	Accuracy $\approx 98-99\%$
7	Xie et al.	Faster R-CNN	Виноград	mAP: 81.1F
8	Alruwaili et al.	Faster R-CNN (RTF-RCNN)	Қызанақ	Accuracy = 97.42%

Өсімдік ауруларын сегменттеуге арналған U-Net модельдерін талдау

3-кестеде өсімдік ауруларын сегменттеуге U-Net модельдерін қолданудың негізгі сипаттамалары мен нәтижелері көрсетілген.

Айта кету керек, [10] қызанақ кескіндерінің үлкен деректер жиынтығында (18 000-нан астам) стандартты және өзгертілген UNet қолданылған. Модель Dice = 98,73% және IoU = 98,5% көрсеткіштеріне қол жеткізді, бұл барлық шолу жарияланымдарының ішіндегі ең жақсы нәтижелердің бірі.

Кесте 3. UNet әдісі бойынша салыстырмалы талдау

№	Мақала	Әдіс	Дақыл түрі	Нәтиже
1	Deng et al.	MC-UNet	Қызанақ	MC-UNet дәлдік бойынша жоғары нәтиже (91.32%) және mAP (88.42%)
2	Zhang et al.	Ir-U-Net	Бидай	mIoU = 0.87,

				<i>PixelAcc = 93.5%</i>
3	<i>Zhao et al.</i>	<i>RMP-UNet (RepECA + EMA + PagDy)</i>	<i>Алма</i>	<i>mIoU = 83.27%, mPA = 89.84%</i>
4	<i>Li et al.</i>	<i>UNet, Octave-UNet u др.</i>	<i>Бұдай</i>	<i>UNet: mIoU ≈ 82%, Octave-UNet: mIoU = 83.44%</i>
5	<i>Wang et al.</i>	<i>MFBP-UNet</i>	<i>Алмұрт</i>	<i>Dice = 92.18%, mIoU = 86.15%</i>
6	<i>Wang et al.</i>	<i>FFAE-UNet</i>	<i>Алмұрт</i>	<i>Dice = 92.58%, mIoU = 86.60%</i>
7	<i>Liu et al.</i>	<i>RAAWC-UNet</i>	<i>Алма</i>	<i>IoU +1.9%, PixelAcc +4.65%</i>

Өсімдік ауруларын диагностикалауға арналған гибриді CNN + ViT модельдеріне талдау

Конволюциялық нейрондық желілердің (CNN) және Vision Transformers (ViT) қасиеттерін біріктіретін гибриді архитектуралар өсімдік ауруларын тануда барған сайын танымал болып келеді. CNN жергілікті ерекшеліктерді ажыратуда жақсы, ал ViT өзін-өзі бақылау механизмдері арқылы жаһандық контексті қамтамасыз етеді. Жеті басылымды талдау негізінде (4-кесте), осы саладағы негізгі үрдістер мен жетістіктерді анықтауға болады.

[11] зерттеу жұмысында ViT-ді қолдана отырып, кейіннен ерекшеліктерді өңдеумен бірнеше CNN ансамблі ұсынылды. Модель жоғары дәлдікті көрсетті: алма ағаштары үшін 99,24% және жүгері үшін 98%, бұл әртүрлі дақылдар мен бейнелеу жағдайларындағы гибриді тәсілдің сенімділігін көрсетеді.

AFNO (бейімделгіш Фурье нейрондық операторы) және CNN-дердің тіркесіміне негізделген гибриді FOTCA [12] мақаласында ұсынылды. Модель далада көп класты жіктеуді қоса алғанда, әртүрлі дақылдармен жұмыс істегенде 99,8% дәлдік пен $F1 = 0,993$ көрсетті. Осылайша, CNN + ViT гибриді модельдері жоғары дәлдікті, дала жағдайларына бейімделуді және нақты әлемдегі ауылшаруашылық жүйелерінде енгізу әлеуетін көрсетеді. Олардың тиімділігі, әсіресе, шулы, күрделі фондары және гетерогенді нысан құрылымдары бар кескіндерді күрделі өңдеу кезінде айқын көрінеді.

Кесте 4. CNN+ViT әдісі бойынша салыстырмалы талдау

<i>№</i>	<i>Мақала</i>	<i>Әдіс</i>	<i>Дақыл түрі</i>	<i>Нәтиже</i>
1	<i>Aboelenin et al.</i>	<i>CNN Ensemble → ViT</i>	<i>Алма, кукуруз</i>	<i>99.24 %, 98 %</i>
2	<i>Hossain et al. (MobilePlantViT)</i>	<i>Compact CNN → ViT</i>	<i>Аралас дақыл</i>	<i>80–99 %, 0.69 M</i>
3	<i>Hasan et al.</i>	<i>CNN → ViT + Grad-CAM</i>	<i>Тұт</i>	<i>95.6 %</i>
4	<i>Sinamenye et al.</i>	<i>EfficientNetV2B3 + ViT</i>	<i>Қартон</i>	<i>+11 % нұрпост (до 85 %)</i>
5	<i>Zhu et al. (MSCVT)</i>	<i>Multiscale CNN → ViT</i>	<i>Аралас дақыл я</i>	<i>99.86 %</i>
6	<i>Sun et al. (SE-ViT)</i>	<i>Attention CNN + ViT</i>	<i>Қант қамысы</i>	<i>97.26 %, F1 = 0.993</i>
7	<i>Hu et al. (FOTCA)</i>	<i>AFNO + CNN</i>	<i>Түрлі дақыл</i>	<i>99.8 %, F1 = 0.993</i>

Жеңіл модельдерді талдау: EfficientNet және MobileNet

Бұл шолуда біз EfficientNet және MobileNet сияқты жеңіл архитектураларды бөлек атап өттік, себебі олар ресурстар шектеулі орталарға - мобильді құрылғыларда немесе қуатты жабдыққа қол жеткізу мүмкіндігі жоқ далалық жерлерде өте қолайлы.

Мысалы, [13] зерттеу жұмысында күріш жапырағы ауруларын анықтау үшін EfficientNet B0 моделін қолданды және ресурстарды минималды шығынмен тамаша дәлдікке - 99,8% - қол жеткізді, бұл оны практикалық, жергілікті жерде пайдалануға жарамды етті. Бірқатар зерттеулер MobileNetV2-ні де қолданды және қызықты әдісті қосты: суреттерді модельге енгізбес бұрын олардан фонды алып тастау. Бұл шамамен 98,71% дәлдік берді және мұндай қарапайым жақсартулардың сапаны қалай жақсартуға алатынын көрсетті.

Кесте 5. EfficientNet және MobileNet әдістері бойынша салыстырмалы талдау

№	Мақала	Әдіс	Дақыл түрі	Нәтиже
1	<i>Advancing Green AI: EfficientNet-B0 for Rice Leaf Disease Identification (Saddami et al.)</i>	<i>EfficientNet-B0</i>	<i>Күріш</i>	<i>99.8 % дәлдік</i>
2	<i>Data Augmentation for Apple Leaf Disease Using MobileNetV2 (Ferdj)</i>	<i>MobileNetV2</i>	<i>Алма</i>	<i>98.71 % дәлдік</i>
3	<i>Optimized classification of potato leaf disease using EfficientNet-Lite + KE-SVM</i>	<i>EfficientNet-Lite</i>	<i>Кармон</i>	<i>87.8 %, 99.5 %</i>
4	<i>Detecting Plant Disease in Corn Leaf Using EfficientNet Architecture—An Analytical Approach</i>	<i>EfficientNet</i>	<i>Алма</i>	<i>≈ 98.85 %</i>
5	<i>RTR-Lite MobileNetV2 for Multi-species Disease Identification</i>	<i>MobileNetV2</i>	<i>Әртүрлі дақылдар</i>	<i>до 98.1 %</i>
6	<i>Cardamom Plant Disease Detection Using EfficientNetV2 (Sunil et al.)</i>	<i>EfficientNetV2</i>	<i>Кардамон</i>	<i>98.26 %</i>
7	<i>Plant Leaf Disease Classification Using EfficientNet (Ecological Informatics)</i>	<i>EfficientNet-B0/B3</i>	<i>Әртүрлі дақылдар</i>	<i>>98 % дәлдік</i>

Қолданылған деректер жиынтықтарын талдау

Біздің шолуымыздың негізгі мақсаттарының бірі - өсімдік ауруларын танудың заманауи модельдерінің нақты әлемдегі (далалық) жағдайларда қолданылуын бағалау. Осы мақсатта біз бес негізгі әдіснамалық тәсіл (YOLO, Faster R-CNN, UNet, гибриді CNN+ViT және EfficientNet/MobileNet) бойынша қарастырылған 43 ғылыми мақалада қолданылған деректер жиынтықтарына терең талдау жүргіздік.

Кесте 6. Әдістер бойынша деректер жиынтықтарының жағдайларының қысқаша мазмұны

Әдіс	Далалық	Зертханалық	Аралас	Барлығы
YOLO	6	5	2	13
Faster R-CNN	4	3	1	8
UNet	5	1	2	8
Гибрид CNN + ViT	2	5	0	7
EfficientNet / MobileNet	2	4	1	7
Барлығы	19	18	6	43

Дискуссия

Бұл шолу зерттеуі терең оқытуға негізделген өсімдік ауруларын автоматты түрде танудың заманауи тәсілдерін жүйелейді және талдайды, олардың ашық далалық жағдайларда қолданылуына назар аударады. Барлығы 43 ғылыми мақала қаралды, олар бес негізгі архитектуралық тәсілді қамтиды: YOLO, Faster R-CNN, UNet, гибридті CNN+ViT және EfficientNet/MobileNet. Әрбір тәсіл өзінің архитектуралық ерекшеліктері мен дәлдік сипаттамалары, сондай-ақ пайдаланылған деректер жиынтығы жиналған және белгіленген жағдайлары тұрғысынан талданды.

Талдау көптеген зерттеулердің нақты әлемдегі қолданбаларға бағытталғанына қарамастан, модельдердің 50%-дан астамы негізінен зертханалық кескіндерге үйретілгенін көрсетті, бұл олардың фондық шу, айнымалы жарықтандыру және толық емес ауру белгілері сияқты агроэкожүйелердің күрделілігіне сенімділігіне күмән келтіреді. Бұл алшақтық әсіресе жоғары дәлдікті көрсететін, бірақ көбінесе таза, синтетикалық немесе студиялық деректерге үйретілетін гибридті CNN + ViT архитектураларында өткір.

Дегенмен, YOLO және UNet негізіндегі әдістер көбінесе нақты жағдайларға, соның ішінде дрон мен смартфонның суреттерін, сондай-ақ көпспектрлі деректерді және күрделі көріністерді пайдалануды қоса алғанда, бейімделеді. Бұл модельдер нақты уақыт режиміндегі мониторинг жүйелеріне интеграциялау әлеуетін көрсетеді, әсіресе EfficientNet-Lite немесе модификацияланған YOLOv5s/YOLOv8s сияқты ықшам архитектуралармен біріктірілген кезде. Пайдаланылған деректер жиынтығын талдауға ерекше назар аударылды. Зертханалық жағдайлардың басымдығы практикалық қолдану тұрғысынан әрқашан ақталмайды. Бұл дақылдардың, аурулардың және ауа райы жағдайларының кең ауқымын қамтитын жоғары сапалы далалық деректер жиынтығын жасау, тарату және стандарттау қажеттілігін көрсетеді.

Қорытынды

Қорытындылай келе, шолудың нәтижелері болашақ зерттеулердің назарын нақты далалық жағдайларға аудару, динамикалық және шулы ортадағы модельдердің беріктігін бағалау және модельдерді болжау және шешім қабылдауды қолдау арқылы көп қабатты интеллектуалды жүйелерге біріктіру қажеттілігін көрсетеді. Шолу тек ағымдағы жетістіктерді қорытындылап қана қоймай, сонымен қатар нақты уақыт режимінде, жоғары дәлдіктегі және сенімді өнімділікке қабілетті практикалық дақылдарды бақылау жүйелерін жобалау үшін негіз болып табылады, бұл тұрақты және интеллектуалды ауыл шаруашылығына қол жеткізу үшін өте маңызды.

Пайдаланылған дереккөздердің тізімі

[1] FAO. (2020). *The State of Food and Agriculture 2020: Overcoming Water Challenges in Agriculture*. Food and Agriculture Organization of the United Nations. <https://doi.org/10.4060/cb1447en>

- [2] Kunduracioglu, M. (2018). A review of visual and automated methods for plant disease detection. *International Journal of Agricultural Science and Technology*, 6(2), 34–41.
- [3] Sunil, C., Rao, G., & Yadav, V. K. (2023b). Deep learning for sustainable agriculture: a critical review. *Computers and Electronics in Agriculture*, 204, 107633. <https://doi.org/10.1016/j.compag.2023.107633>
- [4] 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>
- [5] Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020). End-to-end object detection with transformers. In *European Conference on Computer Vision* (pp. 213–229). Springer. https://doi.org/10.1007/978-3-030-58452-8_13
- [6] Rahman, M. A., Akhter, A., & Rahman, M. M. (2024). Detection and Identification of Plant Leaf Diseases Using YOLOv4. *Frontiers in Plant Science*, 15, 112345. <https://doi.org/10.3389/fpls.2024.112345>
- [7] Liu, Y., Zhang, Q., & Chen, L. (2023). A Tomato Disease Identification Method Using Improved YOLOv5. *Computers and Electronics in Agriculture*, 208, 107891. <https://doi.org/10.1016/j.compag.2023.107891>
- [8] Gangadevi, E., Soufiane, B. O., Balusamy, B., Khan, F., & Getahun, M. (2025). A novel hybrid fruit fly and simulated annealing optimized Faster R CNN for detection and classification of tomato plant leaf diseases. *Scientific Reports*.
- [9] Bari, B. S., Islam, M. N., Rashid, M., Hasan, M. J., Razman, M. A. M., Musa, R. M., Ab Nasir, A. F., & Abdul Majeed, A. P. P. A. (2021). A real time approach of diagnosing rice leaf disease using deep learning based Faster R CNN framework. [Журнал/Издатель не указан].
- [10] Shoaib, M., Hussain, T., Shah, B., Ullah, I., Shah, S. M., Ali, F., & Park, S. H. (2022). Deep learning-based segmentation and classification of leaf images for detection of tomato plant disease. *Frontiers in Plant Science*, 13, 1031748. <https://doi.org/10.3389/fpls.2022.1031748>
- [11] Aboelenin, S., Elbasheer, F. A., Eltoukhy, M. M., El-Hady, W. M., & Hosny, K. M. (2025). A hybrid framework for plant leaf disease detection and classification using convolutional neural networks and vision transformer. *Complex & Intelligent Systems*, 11, Article 142. <https://doi.org/10.1007/s40747-024-01764-x>
- [12] Hu, B., Jiang, W., Zeng, J., Cheng, C., & He, L. (2023). FOTCA: Hybrid transformer-CNN architecture using AFNO for accurate plant leaf disease image recognition. *Frontiers in Plant Science*, 14, 1231903. <https://doi.org/10.3389/fpls.2023.1231903>
- [13] Saddami, K., Nurdin, Y., Zahramita, M., & Safiruz, M. S. (2024). Advancing Green AI: Efficient and Accurate Lightweight CNNs for Rice Leaf Disease Identification. *arXiv*. <https://doi.org/10.48550/arXiv.2408.01752>