

**ԲՈՒՅՍԵՐԻ ՀԻՎԱՆԴՈՒԹՅՈՒՆՆԵՐԻ ՀԱՅՏՆԱԲԵՐՈՒՄԸ ԽՈՐԸ ՈՒՍՈՒՑՄԱՆ
ԵՒ YOLOv11 ՍՈՂԵԼԻ ԿԻՐԱՌՄԱՄԲ**

ԱՎԵՏԻՍՅԱՆ ՎԱՐԱԶԴԱՏ

Տեխնիկական գիտությունների թեկնածու,
ԳՊՀ ինֆորմատիկայի և ֆիզիկամաթեմատիկական
գիտությունների ամբիոնի վարիչ
e-mail: v.avetisyan@gsu.am

ՍԱՐԳՍՅԱՆ ՄԱՐԱՏ

ԳՊՀ բնագիտատնտեսագիտական ֆակուլտետի
«Համակարգչային ճարտարագիտություն» մասնագիտության
մագիստրատուրայի 2-րդ կուրսի ուսանող
e-mail: maratsargsyan48@gmail.com

Բույսերի հիվանդությունները հանդիսանում են գյուղատնտեսության ոլորտի հիմնական խնդիրներից մեկը, որոնք կարող են հանգեցնել բերքատվության զգալի կրճատման և տնտեսական վնասների: Ավանդական ախտորոշման մեթոդները հիմնականում հիմնված են մասնագետների տեսողական փորձի վրա, ինչը ժամանակատար է և հաճախ ենթակա է սուբյեկտիվ սխալների: Ժամանակակից խորը ուսուցման մեթոդները, մասնավորապես կոնվոլյուցիոն նեյրոնային ցանցերը, հնարավորություն են տալիս ավտոմատացնել հիվանդությունների հայտնաբերման գործընթացը՝ օգտագործելով պատկերային տվյալներ:

Այս հոդվածում ներկայացվում է բույսերի հիվանդությունների հայտնաբերման համակարգի իրականացում՝ հիմնված YOLOv11 օբյեկտների հայտնաբերման մոդելի վրա: Ստեղծվել և մշակվել է համապատասխան տվյալների բազա RoboFlow հարթակի միջոցով, իրականացվել է մոդելի ուսուցում, վավերացում և փորձարկում Google Colab միջավայրում GPU արագացմամբ: Ստացված արդյունքները ցույց են տալիս, որ առաջարկվող մոտեցումը արդյունավետ է և կիրառելի իրական պայմաններում:

Բանալի բառեր՝ խորը ուսուցում, բույսերի հիվանդություններ, YOLOv11, օբյեկտների հայտնաբերում, համակարգչային տեսողություն:

ՆԵՐԱԾՈՒԹՅՈՒՆ

Գյուղատնտեսության զարգացումը անմիջականորեն կախված է բույսերի առողջ վիճակից: Բույսերի հիվանդությունները կարող են առաջանալ սևկերի, բակտերիաների, վիրուսների կամ շրջակա միջավայրի անբարենպաստ պայմանների ազդեցությամբ: Ժամանակին

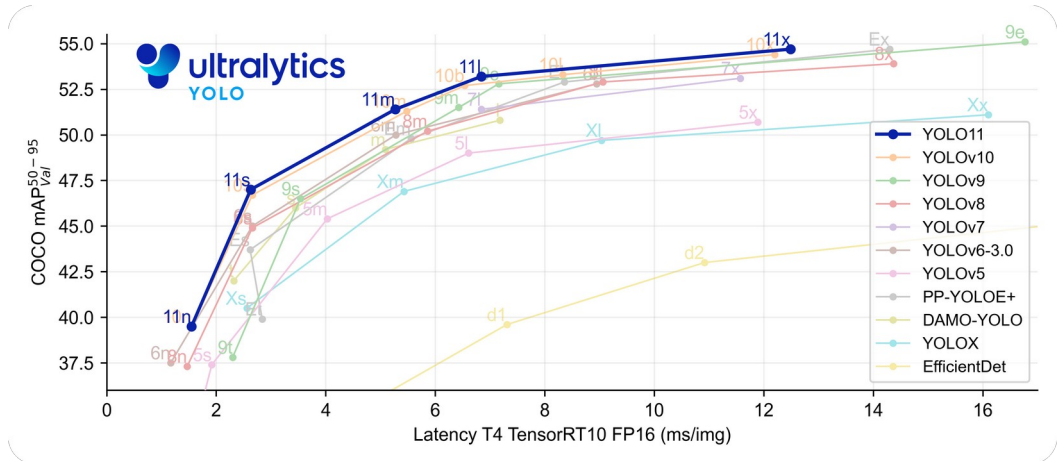
չհայտնաբերվելու դեպքում դրանք կարող են արագ տարածվել և լուրջ վնաս հասցնել բերքին:

Վերջին տարիներին համակարգչային տեսողության և խորը ուսուցման ոլորտներում գրանցված առաջընթացը հնարավորություն է տվել մշակել ավտոմատ համակարգեր, որոնք կարող են վերլուծել բույսերի տերևների պատկերները և հայտնաբերել հիվանդության առկայությունը: Հատկապես լայն կիրառություն են ստացել YOLO (You Only Look Once) ընտանիքի մոդելները, որոնք ապահովում են բարձր արագություն և ճշգրտություն:

YOLOv11-ը YOLO ճարտարապետության վերջին տարբերակներից մեկն է, որը բարելավված է ինչպես կառուցվածքային, այնպես էլ հաշվարկային արդյունավետության տեսանկյունից: Այս աշխատանքի նպատակն է ուսումնասիրել YOLOv11 մոդելի կիրառելիությունը բույսերի հիվանդությունների հայտնաբերման խնդրում և գնահատել դրա արդյունավետությունը փորձարարական տվյալների հիման վրա:

Գրականության ակնարկ

Բույսերի հիվանդությունների ավտոմատ հայտնաբերման համար առաջարկվել են բազմաթիվ մեթոդներ՝ սկսած դասական մեքենայական ուսուցման ալգորիթմներից (SVM, KNN, Random Forest) մինչև խորը նեյրոնային ցանցեր: Վերջին տարիներին առավել արդյունավետ են համարվել կոնվոլյուցիոն նեյրոնային ցանցերը (CNN), որոնք կարողանում են ավտոմատ կերպով դուրս բերել կարևոր հատկանիշներ պատկերներից: YOLO մոդելները հանդիսանում են մեկփուլ օբյեկտների հայտնաբերման ալգորիթմներ, որոնք մեկ առաջանցիկ անցումով միաժամանակ իրականացնում են թե՛ օբյեկտի տեղորոշում, թե՛ դասակարգում: YOLOv11-ը բարելավում է նախորդ տարբերակների թերությունները՝ առաջարկելով ավելի լավ ճշգրտություն փոքր օբյեկտների դեպքում և ավելի ցածր հաշվարկային բարդություն:

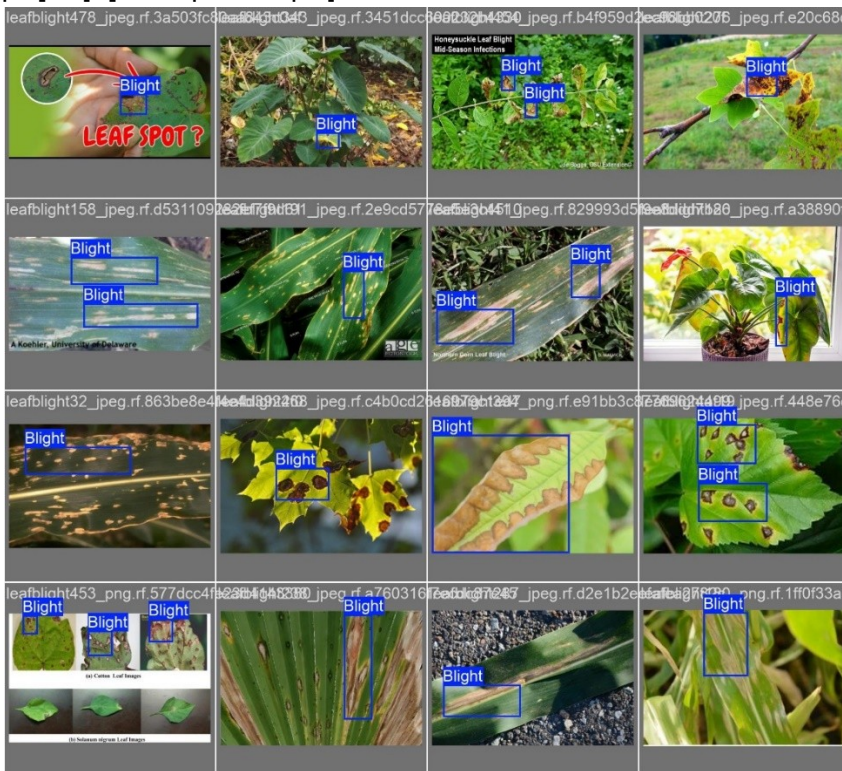


Նկար 1. YOLO մոդելների համեմատություն՝ COCO mAP և Latency ցուցանիշներով TensorRT FP16 միջավայրում
Տվյալների բազայի պատրաստում

Տվյալների բազայի պատրաստումը խորը ուսուցման վրա հիմնված մոդելների արդյունավետ աշխատանքի կարևորագույն փուլերից մեկն է: Մոդելի վերջնական ճշգրտությունն ու ընդհանրացման կարողությունը մեծապես կախված են տվյալների որակից, բազմազանությունից և ընտրված ճարտարապետությանը համապատասխանությունից: Այս աշխատանքի շրջանակներում տվյալների բազայի ստեղծման և կառավարման համար օգտագործվել է RoboFlow հարթակը, որը թույլ է տալիս կազմակերպել ամբողջ գործընթացը՝ սկսած պատկերների հավաքագրումից մինչև մոդելի ուսուցման համար պատրաստ արտահանումը:

Պատկերների հավաքագրում

Տվյալների բազայում ներառված պատկերները հավաքագրվել են բաց աղբյուրներից և ներկայացնում են բույսերի տերևներ տարբեր հիվանդությունների առկայությամբ, ինչպես նաև առողջ օրինակներ: Պատկերները ընտրվել են տարբեր լուսավորության, ֆոնի և դիտման անկյունների պայմաններում մոդելի ընդհանրացնող հատկությունները բարելավելու նպատակով:



Նկար 2. Նկարների հավաքագրում RoboFlow-ում

Պիտակավորում

Պատկերների պիտակավորումը իրականացվել է սահմանային ուղղանկյունների (bounding boxes) միջոցով, որոնք ընդգծում են

հիվանդությամբ ախտահարված հատվածները: Պիտակավորման գործընթացը կատարվել է Roboflow հարթակի գործիքներով՝ համատեղելով ձեռքով պիտակավորումը և ավտոմատ առաջարկվող սահմանները: Այս մոտեցումը նվազեցրել է մարդկային սխալների հավանականությունը և բարձրացրել պիտակավորման ճշգրտությունը:



Նկար 3. Բույսերի հիվանդ հատվածների պիտակավորում

Տվյալների համապատասխանեցում YOLOv11 ձևաչափին

Քանի որ տվյալ հետազոտությունում կիրառվում է YOLOv11 օբյեկտների հայտնաբերման մոդելը, տվյալների բազան անհրաժեշտ էր համապատասխանեցնել հենց այդ ճարտարապետության պահանջներին: YOLOv11-ը օգտագործում է հատուկ պիտակավորման ձևաչափ, որտեղ յուրաքանչյուր օբյեկտ նկարագրվում է դասի ինդեքսով և նորմալացված սահմանային ուղղանկյան կոորդինատներով (x_center, y_center, width, height): Roboflow հարթակը հնարավորություն է տալիս ավտոմատ կերպով արտահանել տվյալների բազան YOLOv11 ձևաչափով՝ ապահովելով պիտակների և պատկերների ճիշտ կառուցվածքը: Արտահանման ընթացքում ստեղծվել է համապատասխան data.yaml ֆայլը, որը պարունակում է դասերի անվանումները, պատկերների ուղիները և ուսուցման, վավերացման ու թեստավորման ենթաբազմությունների նկարագրությունը: Սա ապահովում է տվյալների լիարժեք համատեղելիությունը Ultralytics YOLOv11 գրադարանի հետ:

Dataset-ի ներբեռնում և նախապատրաստում YOLOv11 մոդելի համար Google Colab միջավայրում:

1. `!mkdir {HOME}/datasets`
2. `%cd {HOME}/datasets`

3. `from google.colab import userdata`
4. `from roboflow import Roboflow`
5. `!pip install roboflow`
6. `from roboflow import Roboflow`
7. `rf = Roboflow(api_key="████████████████████")`
8. `project = rf.workspace("lesson-yqgu6").project("bright-m5fyv")`
9. `version = project.version(1)`
10. `dataset = version.download("yolov11")`

Մոդելի ուսուցում

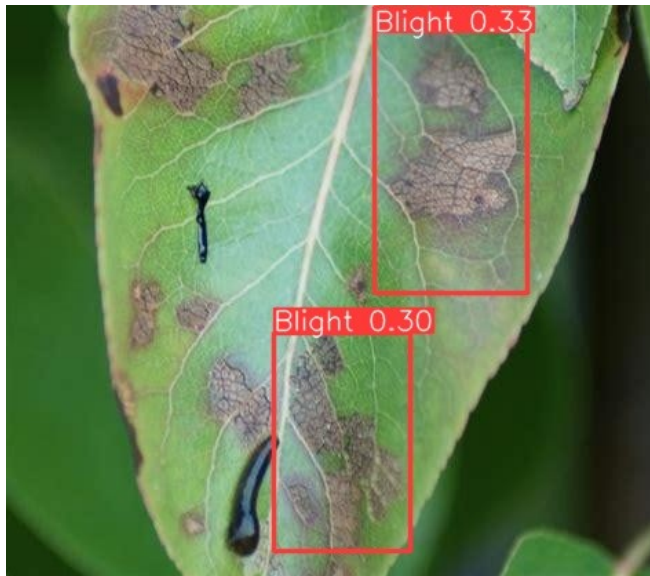
Մոդելը ուսուցանվել է 10 էպոխ՝ 640×640 չափի պատկերներով: Ուսուցման ընթացքում վերահսկվել են կորուստի ֆունկցիաները և վավերացման արդյունքները:

1. `%cd {HOME}`
2. `!yolo task=detect mode=train model=yolo11s.pt data=/content/datasets/Bright-1/data.yaml epochs=10 imgsz=640 plots=True`

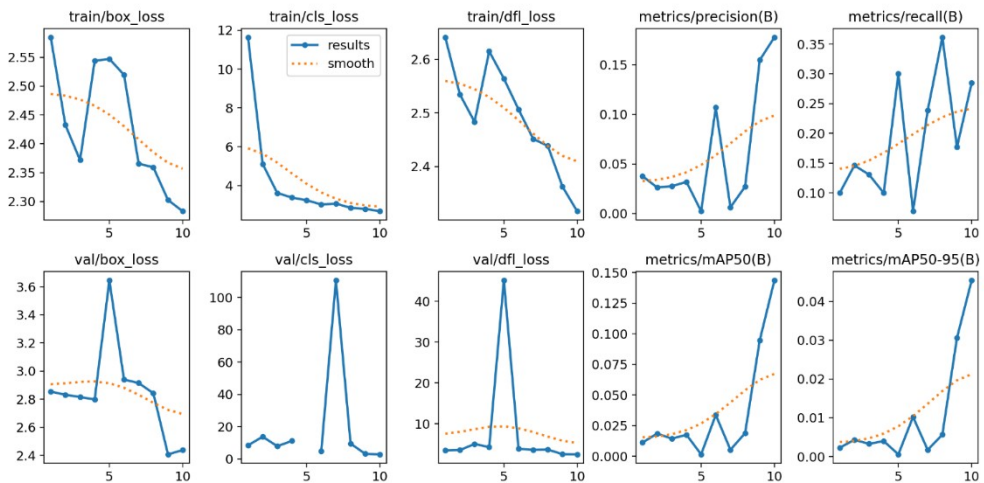
Արդյունքներ

Ուսուցված մոդելի վավերացումը ցույց է տվել, որ այն կարողանում է ճշգրիտ հայտնաբերել բույսերի հիվանդ հատվածները տարբեր պատկերներում: Ստացված կանխատեսումները վիզուալ տեսքով ներկայացվել են, որտեղ նկատվում է օբյեկտների ճիշտ տեղորոշում: Չնայած դրական արդյունքներին, սահմանափակ էպոխների քանակը կարող է ազդել մոդելի առավելագույն հնարավորությունների վրա:

1. `import glob`
2. `from IPython.display import Image, display`
3. `for image_path in`
`glob.glob(f'/content/runs/detect/predict/100_408371cc_jpg.rf.6712b0061c611`
`57961759a6bad57d559.jpg'):`
4. `display(Image(filename=image_path, width=600))`



Նկար 4. Ծրագրի աշխատանքի վերջնական արդյունքը, որտեղ իրականացվում է հիվանդությամբ ախտահարված տարածքների հայտնաբերում և նշում:



Նկար 5. Օբյեկտների հայտնաբերման YOLOv11 մոդելի ուսուցման կորերի վերլուծություն:

Նկարում պատկերված են YOLOv11 նեյրոնային ցանցի ուսուցման դիսկրետային արտադրող կորերը 10 դարաշրջանների (epochs) կտրվածքով: Հետազոտության արդյունքների վերլուծությունը թույլ է տալիս գնահատել մոդելի կայունությունը և օբյեկտների հայտնաբերման արդյունավետությունը:

Կորստի ֆունկցիաների վերլուծություն (Loss Functions): Ուսուցման փուլում (train/box_loss, train/cls_loss, train/dfl_loss) նկատվում է կորստի ցուցանիշների հետևողական նվազում, ինչը վկայում է ալգորիթմի օպտիմալացման և կշիռների ճիշտ թարմացման մասին: Մասնավորապես,

դասակարգման կորուստը (cls_loss) ցուցաբերում է կորուկ անկում առաջին ետապներում՝ արագորեն հասնելով կայունացման սահմանին: Վալիդացման փուլի (val) կորերը նույնպես դրսևորում են նվազման միտում, սակայն 5-րդ և 7-րդ դարաշրջանների միջակայքում դիտվում են որոշակի տատանումներ (spikes): Սա կարող է պայմանավորված լինել տվյալների բազմազանությամբ կամ մոդելի կողմից բարդ օրինակների յուրացման փորձով: Այդուհանդերձ, ուսուցման ավարտին (10-րդ epoch) վալիդացման կորուստները հասնում են իրենց նվազագույն արժեքներին, ինչը փաստում է մոդելի ընդհանրացման (generalization) բարձր ունակության մասին:

Արդյունավետության մետրիկաներ (Evaluation Metrics): Մոդելի որակական ցուցանիշները՝ ճշգրտությունը (metrics/precision) և ամբողջականությունը (metrics/recall), ուսուցման ավարտին դրսևորում են աճի կայուն դինամիկա: Հատկանշական է mAP50 և mAP50-95 (Mean Average Precision) ցուցանիշների վարքագիծը.

mAP50 ցուցանիշը վերջին դարաշրջաններում հասնում է իր առավելագույնին՝ արձանագրելով զգալի թռիչք 8-րդ դարաշրջանից հետո:

mAP50-95 ցուցանիշի աճը փաստում է, որ մոդելը դառնում է ավելի ճշգրիտ ոչ միայն օբյեկտի տեսակի որոշման, այլև դրա տեղադրման սահմանների (Bounding Box) հստակեցման հարցում:

Եզրակացություն

Այս աշխատանքում իրականացվել է բույսերի հիվանդությունների հայտնաբերման համակարգ YOLOv11 մոդելի հիման վրա: Կարելի է եզրակացնել, որ YOLOv11 մոդելը հաջողությամբ ադապտացվել է տվյալների բազային: Արդյունքները ցույց են տալիս, որ խորը ուսուցման ժամանակակից մեթոդները կարող են արդյունավետորեն կիրառվել գյուղատնտեսական խնդիրների լուծման համար:

Օգտագործված գրականության ցանկ

1. Ultralytics. (թթ. 2025). Model Prediction with Ultralytics YOLO, Modes-Predict. Մատյան՝ Ultralytics YOLO Documentation. Վերցված՝ <https://docs.ultralytics.com/modes/predict/>
2. Կոնդավետի, Հ.Բ., & Սիմհադրի, Ճ.Գ. (2025). Բնական ցորենի տերևների հիվանդությունների հայտնաբերման համար խոր ուսուցման մոդելների գնահատում բացատրելի արհեստական ինտելեկտի միջոցով՝ որակական և քանակական վերլուծությամբ. Scientific Reports, 15, 31850. <https://doi.org/10.1038/s41598-025-14306-3>
3. Roboflow. (թթ. 2025). YOLO11 Object Detection Model. Մատյան՝ Roboflow. Վերցված՝ <https://roboflow.com/model/yolo11/>
4. Ֆերենտինոս, Կ. Պ. (2018). Խոր ուսուցման մոդելներ բույսերի հիվանդությունների հայտնաբերման և ախտորոշման համար. Computers and Electronics in Agriculture, 145, 311-318.
5. Թոմ, Է. Կ., Յուլիան, Լ., Նջուկի, Ս., & Յինգչուն, Լ. (2019). Խոր ուսուցման մոդելների մանր հարմարման համեմատական ուսումնասիրություն բույսերի հիվանդությունների հայտնաբերման համար. Computers and Electronics in Agriculture, 161, 272-279.
6. Սլադոնիչ, Ս., Արսենովիչ, Մ., Անդերլա, Ա., Կուլիբրո, Դ., & Ստեֆանովիչ, Դ. (2016). Խոր նեյրոնային ցանցերի վրա հիմնված բույսերի հիվանդությունների ճանաչում տերևների պատկերների դասակարգման միջոցով. Computational Intelligence and Neuroscience, 2016, 3289801.

IMPLEMENTATION OF A PLANT DISEASE DETECTION SYSTEM BASED ON THE YOLOV11 DEEP LEARNING MODEL

AVETISYAN VARAZDAT

*Candidate of Technical Sciences,
Head of the Department of Informatics and Physical-Mathematical Sciences,
Gavar State University
e-mail: v.avetisyan@gsu.am*

SARGSYAN MARAT

*Master's 2nd-year student of the Faculty of Natural Sciences and Economics,
"Computer Engineering" specialization,
Gavar State University
e-mail: maratsargsyan48@gmail.com*

Plant diseases constitute one of the major challenges in the agricultural sector, as they can lead to significant yield reductions and substantial economic losses. Traditional diagnostic methods are primarily based on the visual expertise of specialists, which is time-consuming and often subject to subjective errors. Modern deep learning approaches, particularly convolutional neural networks, enable the automation of disease detection processes through the analysis of image data. This article presents the implementation of a plant disease detection system based on the YOLOv11 object detection model. A dedicated dataset was created and prepared using the Roboflow platform, while model training, validation, and testing were conducted in the Google Colab environment with GPU acceleration. The experimental results demonstrate that the proposed approach is effective and suitable for practical real-world applications.

Keywords: deep learning, plant diseases, YOLOv11, object detection, computer vision.

РЕАЛИЗАЦИЯ СИСТЕМЫ ОБНАРУЖЕНИЯ БОЛЕЗНЕЙ РАСТЕНИЙ НА ОСНОВЕ МОДЕЛИ ГЛУБОКОГО ОБУЧЕНИЯ YOLOv11

АВETИСЯН ВАРАЗДАТ

*Кандидат технических наук,
Заведующий кафедрой информатики и физико-математических наук
Гаварского государственного университета
e-mail: v.avetisyan@gsu.am*

САРГСЯН МАРАТ

*Магистрант 2-го курса факультета естественно-экономических наук,
специальность «Компьютерная инженерия»,
Гаварский государственный университет
e-mail: maratsargsyan48@gmail.com*

Болезни растений являются одной из основных проблем в сельскохозяйственном секторе, поскольку они могут приводить к значительному снижению урожайности и существенным экономическим потерям. Традиционные методы диагностики в основном основаны на визуальном опыте специалистов, что является трудоёмким процессом и часто подвержено субъективным ошибкам. Современные подходы глубокого обучения, в частности сверточные нейронные сети, позволяют автоматизировать процессы выявления заболеваний за счёт анализа изображений.

В данной статье представлена реализация системы обнаружения болезней растений на основе модели обнаружения объектов YOLOv11. Специализированный набор данных был создан и подготовлен с использованием платформы Roboflow, а обучение, валидация и тестирование модели проводились в среде Google Colab с использованием GPU-ускорения. Экспериментальные результаты показывают, что предложенный подход является эффективным и пригодным для практического применения в реальных условиях.

Ключевые слова: глубокое обучение, болезни растений, YOLOv11, обнаружение объектов, компьютерное зрение.