Central Asian Research Journal of Natural and Exact Sciences
INTERNATIONAL SCIENTIFIC, APPLIED AND THEORETICAL JOURNAL
2026 / № 1(2)
SCIENCE FOR A SUSTAINABLE CENTRAL ASIA

LABORATORIYA VA DALA TASVIRLARIDA EKIN KASALLIKLARINI ANIQLOVCHI KONVOLYUTSION NEYRON TARMOQ ARXITEKTURALARINING QIYOSIY TAHLILI

Orazimbetov Akbarali

magistrant
Xudayberdiyev Mirzaakbar Xaqqulmirzayevich

t.f.d., professor
Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti

Annotatsiya. Maqolada qishloq xo‘jalik ekinlari kasalliklarini barg tasvirlari asosida aniqlashda keng qo‘llaniladigan sakkizta chuqur neyron tarmoq arxitekturasi, ya’ni VGG16, ResNet50, MobileNetV3, EfficientNet-B0, EfficientNetV2-S, ConvNeXt-T, Swin-T va ViT-S/16, bir xil sharoitda o‘qitilib, laboratoriya (PlantVillage) va dala (PlantDoc) tasvirlarida qiyosiy baholangan. Laboratoriya tasvirlarida barcha modellar 99,7–99,9 % aniqlikka erishgan bo‘lsa, dala tasvirlarida aniqlik 28,4–37,7 % gacha pasaygan. Eng kichik farq ResNet50 arxitekturasida kuzatilgan. Olingan natijalar ekin kasalliklarini aniqlash modellarini faqat laboratoriya to‘plamlarida baholash ularning amaliy samaradorligini ortiqcha baholashga olib kelishini ko‘rsatadi.

Kalit so‘zlar: konvolyutsion neyron tarmoq, Vision Transformer, ko‘chirib o‘qitish, o‘simlik kasalliklari, domen siljishi, PlantVillage, PlantDoc.

Аннотация. В статье восемь широко применяемых архитектур глубоких нейронных сетей (VGG16, ResNet50, MobileNetV3, EfficientNet-B0, EfficientNetV2-S, ConvNeXt-T, Swin-T и ViT-S/16) обучены в одинаковых условиях и сравнены при распознавании болезней сельскохозяйственных культур по изображениям листьев, снятым в лабораторных (PlantVillage) и полевых (PlantDoc) условиях. На лабораторных изображениях все модели достигли точности 99,7–99,9 %, тогда как на полевых изображениях точность снизилась до 28,4–37,7 %. Наименьший разрыв показала архитектура ResNet50. Результаты показывают, что оценка моделей

только на лабораторных наборах данных приводит к завышенной оценке их практической эффективности.

Ключевые слова: сверточная нейронная сеть, Vision Transformer, перенос обучения, болезни растений, сдвиг домена, PlantVillage, PlantDoc.

Abstract. Eight widely used deep neural network architectures (VGG16, ResNet50, MobileNetV3, EfficientNet-B0, EfficientNetV2-S, ConvNeXt-T, Swin-T and ViT-S/16) were trained under identical conditions and compared for crop disease recognition from leaf images taken in laboratory (PlantVillage) and field (PlantDoc) conditions. All models reached 99.7–99.9 % accuracy on laboratory images, whereas accuracy dropped to 28.4–37.7 % on field images. The smallest gap was observed for ResNet50. The results show that evaluating models on laboratory datasets alone overestimates their practical performance.

Keywords: convolutional neural network, Vision Transformer, transfer learning, plant diseases, domain shift, PlantVillage, PlantDoc.

Kirish

Qishloq xo‘jaligi ishlab chiqarishida ekin kasalliklari hosil miqdori va sifatini pasaytiruvchi asosiy omillardan biri hisoblanadi. FAO huzuridagi O‘simliklarni himoya qilish xalqaro konvensiyasi kotibiyatining 2021-yilgi sharhiga ko‘ra, zararkunanda va kasalliklar jahon ekin mahsulotlarining 40 foizigacha qismini nobud qiladi, faqat o‘simlik kasalliklari keltiradigan yillik iqtisodiy zarar esa 220 milliard AQSh dollaridan oshadi [1]. Kasallikning dastlabki belgilarini o‘z vaqtida aniqlash kimyoviy ishlov berish hajmini kamaytirish va hosilni saqlab qolish imkonini beradi. Ammo bu ish ko‘p hollarda tajribali agronomning bevosita ko‘zdan kechirishiga tayanadi va katta maydonlarda muntazam bajarilishi qiyin.

Raqamli texnologiyalarning rivojlanishi bilan barg fotosurati orqali kasallikni avtomatik aniqlovchi tizimlarga qiziqish ortib bormoqda. O‘zbekiston Respublikasi Prezidentining 2024-yil 14-oktabrdagi PQ-358-son qarori bilan tasdiqlangan sun’iy

intellekt texnologiyalarini rivojlantirish strategiyasida ham qishloq xo‘jaligi sun’iy intellektni joriy etishning ustuvor sohalaridan biri sifatida belgilangan [2]. Bunday tizimlarning asosini, odatda, ImageNet to‘plamida [3] oldindan o‘qitilgan va kasallik tasvirlarida qayta sozlangan chuqur neyron tarmoqlar tashkil etadi.

Adabiyotlarda turli arxitekturalar uchun 97–99 foizdan yuqori aniqlik qayd etilgan. Biroq bu natijalarning aksariyati laboratoriya sharoitida, bir xil fonda olingan tasvirlarda olingan va turli mualliflar tomonidan turlicha o‘qitish sharoitida hisoblangan. Shu sababli arxitekturalarni bir-biri bilan to‘g‘ridan-to‘g‘ri solishtirish, ayniqsa ularning dala sharoitidagi barqarorligini baholash qiyin. Mazkur maqolaning maqsadi zamonaviy konvolyutsion va transformer arxitekturalarini yagona o‘qitish protokoli asosida laboratoriya hamda dala tasvirlarida baholash va ular o‘rtasidagi aniqlik farqini miqdoriy jihatdan aniqlashdan iborat.

Adabiyotlar tahlili

Barg tasvirlari bo‘yicha kasalliklarni aniqlash sohasida chuqur o‘qitish usullari AlexNet tarmog‘i [4] ImageNet tanlovida erishgan muvaffaqiyatdan so‘ng keng qo‘llanila boshladi. S. Sladojevic va hammualliflar internet manbalaridan to‘plangan 13 xil kasallik tasvirlarida CaffeNet modeli yordamida 96,3 foiz aniqlikka erishgan [5]. D.P. Hughes va M. Salathé tomonidan e’lon qilingan PlantVillage ochiq to‘plami [6] bu yo‘nalishdagi tadqiqotlarning asosiy tayanchiga aylandi. Ushbu to‘plamda S.P. Mohanty va hammualliflar GoogLeNet tarmog‘i bilan 38 sinf bo‘yicha 99,35 foiz natija olgan [7]. K.P. Ferentinos 58 sinfli to‘plamda VGG arxitekturasi yordamida 99,53 foizga [8], E.C. Too va hammualliflar esa DenseNet-121 tarmog‘ini nozik sozlash orqali PlantVillage’da 99,75 foiz aniqlikka erishgan [9].

Bu natijalarning amaliy ahamiyati to‘g‘risida tadqiqotchilar tomonidan bir qator e’tirozlar bildirilgan. S.P. Mohanty va hammualliflarning o‘zlari modelni boshqa manbalardan olingan tasvirlarda sinaganda aniqlik 31,4 foizgacha tushganini qayd etgan [7]. J.G.A. Barbedo chuqur o‘qitish natijalariga ma’lumotlar to‘plamining hajmi va xilma-xilligi, tasvirga olish sharoitlari hamda kasallik belgilarining o‘zgaruvchanligi

kuchli ta’sir ko‘rsatishini ta’kidlagan [10]. D. Singh va hammualliflar internet tasvirlaridan iborat, 13 o‘simlik turi va 27 sinfni o‘z ichiga olgan 2 598 tasvirli PlantDoc to‘plamini yaratgan [11]. Ular PlantVillage’da o‘qitilgan VGG16 modeli bu tasvirlarda atigi 15,08 foiz aniqlik ko‘rsatishini aniqlagan. Shunga o‘xshash muammolar boshqa ekinlar uchun ham kuzatilgan: kassava kasalliklari [12] va olma bargi kasalliklari [13] bo‘yicha dala tasvirlaridan iborat to‘plamlar ham aynan shu sababli yaratilgan.

Kompyuter ko‘rishning umumiy nazariyasida bu hodisa domen siljishi (domain shift) deb ataladi. A. Torralba va A.A. Efros har bir ma’lumotlar to‘plami o‘ziga xos tizimli og‘ishlarga ega ekanini va unda o‘qitilgan model boshqa to‘plamda sezilarli darajada yomon ishlashini ko‘rsatgan [14]. R. Geirhos va hammualliflar neyron tarmoqlar ko‘pincha masalani yechishning “qisqa yo‘lini” topishini, ya’ni maqsadli obyekt o‘rniga fon yoki tekstura kabi tasodifiy belgilarga tayanishini qayd etgan [15]. Laboratoriya to‘plamida bir xil fon va yoritilganlik aynan shunday tasodifiy belgi bo‘lib xizmat qilishi mumkin.

So‘nggi yillarda VGG [16] va ResNet [17] kabi klassik arxitekturalardan tashqari mobil qurilmalar uchun mo‘ljallangan MobileNetV3 [18], masshtablash qoidasiga asoslangan EfficientNet [19] va EfficientNetV2 [20], transformer g‘oyalarini konvolyutsion tarmoqqa ko‘chirgan ConvNeXt [21] hamda attention mexanizmiga to‘liq asoslangan Vision Transformer [22] va Swin Transformer [23] taklif etildi. Biroq ushbu arxitekturalarning dala tasvirlaridagi barqarorligi yagona sharoitda tizimli solishtirilmagan. Mazkur ishda aynan shu bo‘shliqni to‘ldirishga harakat qilingan.

Tadqiqot metodologiyasi

Ma’lumotlar to‘plamlari

Modellarni o‘qitish uchun PlantVillage to‘plamining rangli tasvirlari ishlatildi. To‘plamda 14 turdagi ekinning 26 xil kasallik va sog‘lom holatlariga tegishli 38 sinfdan iborat 54 mingdan ortiq tasvir mavjud [6, 7]. Tasvirlar har bir sinf ichida tasodifiy ravishda 70:15:15 nisbatda o‘qitish, validatsiya va test qismlariga ajratildi. Dala sharoitidagi baholash uchun PlantDoc to‘plamining test qismi olindi [11]. PlantDoc

sinflari PlantVillage'dagi mos sinflarga qo'lda moslashtirildi, mos sinfi bo'lmagan tasvirlar tahlildan chiqarildi. Natijada dala testi 236 ta tasvir va 27 ta sinfdan iborat bo'ldi. Har ikkala to'plamdan namunalar 1-rasmda, ularning asosiy tavsiflari esa 1-jadvalda keltirilgan.

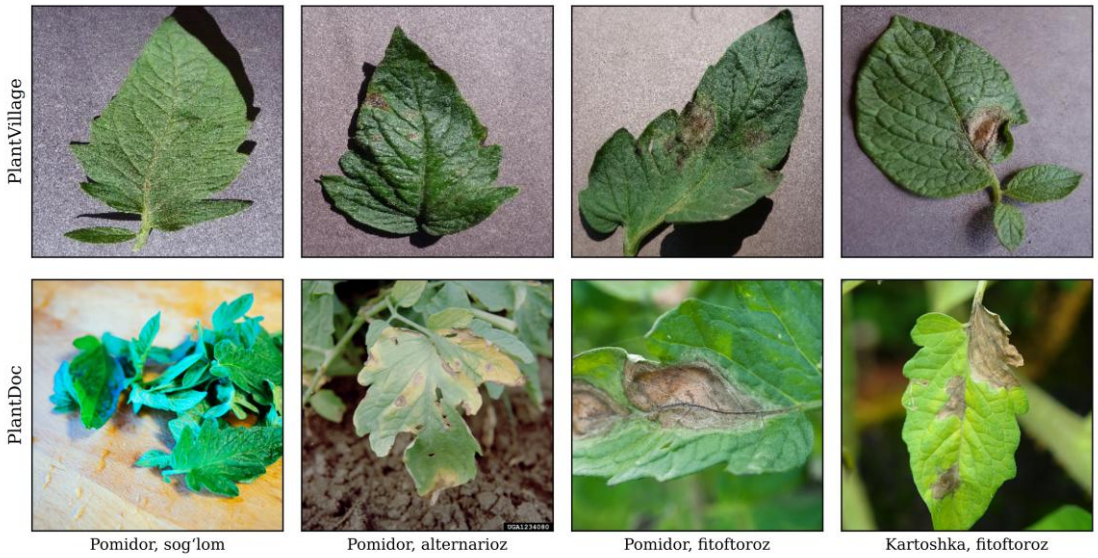

1-rasm. PlantVillage (yuqori qator) va PlantDoc (pastki qator) to'plamlaridan namunalar

Manba: [6] va [11] to'plamlari

1-jadval. Tadqiqotda ishlatilgan ma'lumotlar to'plamlari

Ko'rsatkich	PlantVillage	PlantDoc (test)
Tasvirga olish sharoiti	Laboratoriya, bir xil fon	Dala, internet manbalari
Sinflar soni	38	27 (moslashtirilgan)
Tasvirlar soni	54 mingdan ortiq	236
Tadqiqotdagi vazifasi	O'qitish, validatsiya, test	Faqat test

Modellar

Tadqiqotda qo'llanilgan arxitekturalar 2-jadvalda keltirilgan. Ular klassik konvolyutsion tarmoqlar, mobil qurilmalar uchun yengil tarmoqlar, zamonaviy konvolyutsion tarmoqlar va transformer arxitekturalari kabi to'rt guruhni qamrab oladi. Barcha modellar timm kutubxonasi [24] orqali ImageNet to'plamida oldindan o'qitilgan og'irliklar bilan yuklandi. Ularning oxirgi tasniflash qatlami 38 sinfga moslab

almashtirildi.

2-jadval. Tadqiqotda solishtirilgan arxitekturalar

Model	Yil	Turi	Oldindan o‘qitish	Param., mln
VGG16 [16]	2015	Klassik CNN	ImageNet-1k	134,4
ResNet50 [17]	2016	Qoldiqli CNN	ImageNet-1k	23,6
MobileNetV3-L [18]	2019	Yengil CNN	ImageNet-1k	4,3
EfficientNet-B0 [19]	2019	Yengil CNN	ImageNet-1k	4,1
EfficientNetV2-S [20]	2021	Zamonaviy CNN	ImageNet-21k	20,2
ConvNeXt-T [21]	2022	Zamonaviy CNN	ImageNet-22k	27,8
ViT-S/16 [22]	2021	Transformer	ImageNet-21k	21,7
Swin-T [23]	2021	Ierarxik transformer	ImageNet-22k	27,5

Izoh: parametrlar soni 38 sinfli tasniflash qatlami bilan hisoblangan

O‘qitish sharoiti

Natijalarni adolatli solishtirish uchun barcha modellar bir xil protokol asosida o‘qitildi (3-jadval). Optimallashtirish uchun AdamW algoritmi [25] qo‘llanildi. Oldindan o‘qitilgan qatlamlar uchun o‘qitish tezligi yangi tasniflash qatlamiga nisbatan 10 marta kichik qilib olindi. Bu yondashuv ko‘chirib o‘qitishda oldindan olingan bilimni saqlab qolishga yordam beradi. Validatsiya to‘plamidagi makro-F1 qiymati eng yuqori bo‘lgan epoxadagi og‘irliklar saqlanib, keyingi baholashda ishlatildi. Tajribalar NVIDIA GeForce RTX 3050 (8 GB) grafik protsessorida, PyTorch 2.14.1 (CUDA 12.6) muhitida bajarildi.

3-jadval. O‘qitish parametrlari

Parametr	Qiymati
Tasvir o‘lchami	224 × 224
Optimizator	AdamW, vazn so‘nishi 0,05
O‘qitish tezligi (yangi qatlam / tarmoq)	10^{-3} / 10^{-4}
Tezlik jadvali	Kosinus, 2 epoxa isitish
Epoxalar soni	30 (erta to‘xtatish, 8 epoxa)
Batch o‘lchami	32
Regulyarizatsiya	Label smoothing 0,1; drop-path 0,1; EMA
Augmentatsiya	RandomResizedCrop, aks ettirish, TrivialAugment, Mixup, CutMix, RandomErasing
Aralash aniqlik	FP16 (AMP)

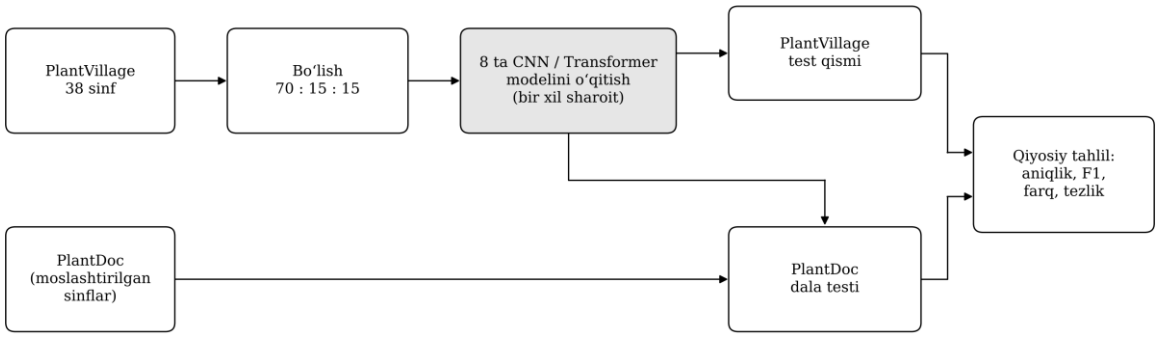

2-rasm. Tadqiqot metodologiyasi sxemasi

Manba: muallif tomonidan ishlab chiqilgan

Baholash ko‘rsatkichlari

Modellar har bir test to‘plamida umumiy aniqlik (accuracy), sinflar bo‘yicha o‘rtacha aniqlik (precision), to‘liqlik (recall) va F1 ko‘rsatkichi bilan baholandi. N ta test tasviri uchun umumiy aniqlik quyidagicha hisoblanadi:

$$Accuracy = (1/N) \cdot \Sigma_i I(\hat{y}_i = y_i), \quad (1)$$

bunda y_i i-tasvirning haqiqiy sinfi, $\hat{y}_i$ model bashorat qilgan sinf, $I(\cdot)$ esa shart bajarilganda 1 ga, aks holda 0 ga teng indikator funksiya. k-sinf uchun precision, recall va F1 quyidagi formulalar bilan aniqlanadi:

$$P_k = TP_k / (TP_k + FP_k), \quad R_k = TP_k / (TP_k + FN_k), \quad F1_k = 2 \cdot P_k \cdot R_k / (P_k + R_k), \quad (2)$$

bunda TP_k, FP_k va FN_k mos ravishda k-sinf uchun to‘g‘ri musbat, noto‘g‘ri musbat va noto‘g‘ri manfiy bashoratlar soni. Sinflar soni teng taqsimlanmaganligi sababli, asosiy ko‘rsatkich sifatida makro-o‘rtacha F1 olindi:

$$F1_macro = (1/K) \cdot \Sigma_k F1_k, \quad (3)$$

bunda K test to‘plamidagi sinflar soni. Laboratoriya va dala tasvirlari orasidagi farq foiz punktlarda quyidagicha hisoblandi:

$$\Delta = Accuracy(PlantVillage) - Accuracy(PlantDoc). \quad (4)$$

Bundan tashqari, har bir model uchun parametrlar soni va bitta tasvirni qayta ishlash vaqti o‘lchandi. Vaqt grafik protsessorda, 10 ta isitish o‘tkazishidan keyin, 100 ta o‘tkazish bo‘yicha o‘rtacha hisoblandi.

Natijalar

Tajribalar natijalari 4-jadvalda va 3-rasmda keltirilgan.

4-jadval. Modellarning laboratoriya va dala tasvirlaridagi natijalari

Model	PV aniqlik, %	PV F1	PD aniqlik, %	PD F1	Δ, f.p.	Vaqt, ms
VGG16	99,78	0,9968	28,39	0,2728	71,4	14,1
ResNet50	99,72	0,9951	37,71	0,3825	62,0	9,3
MobileNetV3-L	99,77	0,9964	34,32	0,3338	65,4	9,8
EfficientNet-B0	99,82	0,9965	34,32	0,3248	65,5	12,3
EfficientNetV2-S	99,78	0,9960	35,17	0,3432	64,6	26,1
ConvNeXt-T	99,91	0,9980	36,02	0,3455	63,9	7,6
ViT-S/16	99,86	0,9975	33,90	0,3181	66,0	8,0
Swin-T	99,89	0,9978	36,44	0,3477	63,5	15,9

Izoh: PV – PlantVillage test to‘plami, PD – PlantDoc dala tasvirlari, Δ – (4) formula bo‘yicha farq.

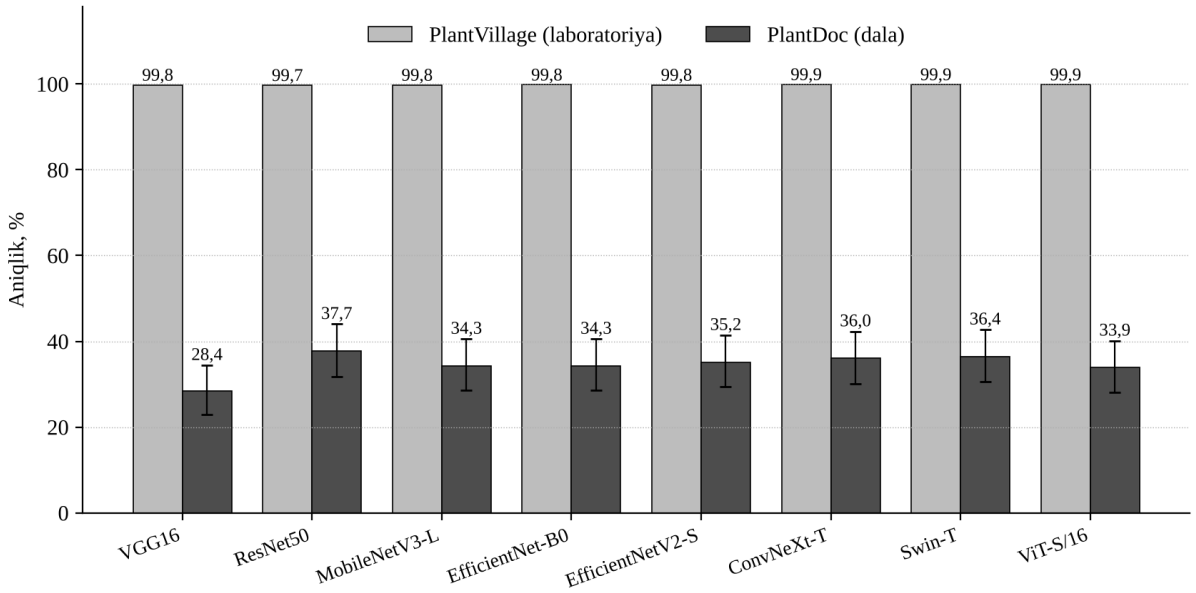

3-rasm. Modellarning laboratoriya va dala tasvirlaridagi aniqligi

Manba: muallif tomonidan o‘tkazilgan tajribalar natijasi

PlantVillage test to‘plamida barcha modellar 99,72–99,91 % aniqlikka erishdi. Eng yuqori natijani ConvNeXt-T (99,91 %), eng pastini esa ResNet50 (99,72 %) ko‘rsatdi. Shunday qilib, laboratoriya tasvirlarida arxitekturalar orasidagi farq 0,2 foiz punktdan oshmadi. Bu natijalar adabiyotlarda keltirilgan 97–99 foizli ko‘rsatkichlar bilan mos keladi [7–9].

PlantDoc dala tasvirlarida esa manzara keskin o‘zgardi. Modellarning aniqligi 28,39–37,71 % oralig‘iga tushdi, laboratoriya va dala o‘rtasidagi farq Δ esa 62,0 dan 71,4 foiz punktgacha yetdi. Dala tasvirlarida eng yaxshi natijani ResNet50 ko‘rsatdi (37,71 %, makro-F1 0,383). Eng katta pasayish VGG16 modelida kuzatildi (Δ = 71,4 foiz punkt). Transformer modellari konvolyutsion tarmoqlarga nisbatan aniq ustunlik ko‘rsatmadi: Swin-T 36,44 % bilan ikkinchi o‘rinni egallagan bo‘lsa, ViT-S/16 33,90 % bilan oxiridan ikkinchi natijani berdi.

Modellarning hisoblash samaradorligi 4-rasmda ko‘rsatilgan. Parametrlar soni bo‘yicha eng katta model VGG16 (134,4 million) bo‘lsa-da, u dala tasvirlarida eng past natijani ko‘rsatdi (28,39 %). Atigi 4,1–4,3 million parametrga ega MobileNetV3 va EfficientNet-B0 modellari dala tasvirlarida bir xil, 34,32 % aniqlik ko‘rsatdi, bitta tasvirni esa mos ravishda 9,8 va 12,3 ms da qayta ishladi. Bu natija 20–28 million parametrli EfficientNetV2-S, ViT-S/16 va ConvNeXt-T modellarinikidan deyarli farq qilmaydi.

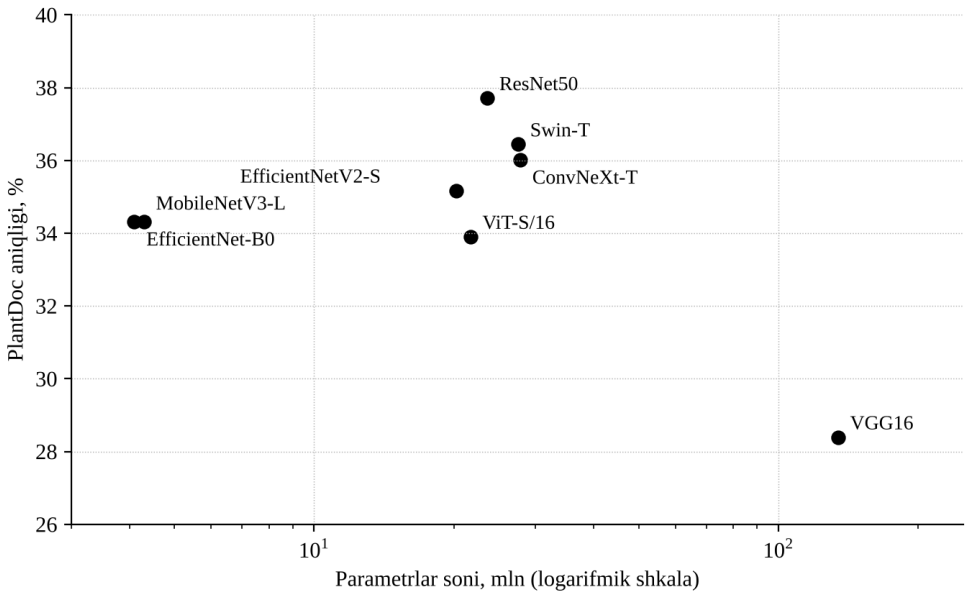

4-rasm. Modellarning parametrlar soni va dala tasvirlaridagi aniqligi

Manba: muallif tomonidan o‘tkazilgan tajribalar natijasi

Dala tasvirlarida eng yaxshi natija ko‘rsatgan ResNet50 modelining xatoliklar matritsasi 5-rasmda berilgan. Xatolarning katta qismi ikki turga bo‘linadi. Birinchisi bitta

ekinning turli holatlari o‘rtasidagi chalkashlik bo‘lib, masalan, uzum qora chirishi bilan zararlangan 8 ta bargning barchasi sog‘lom uzum bargi deb, pomidorning mozaika virusi bilan zararlangan va sog‘lom barglari esa asosan fitoftoroz deb tasniflandi. Makkajo‘xorining uchta kasalligi ham o‘zaro chalkashtirildi. Ikkinchi tur turli ekinlarning sog‘lom barglari o‘rtasida yuz berdi: soya va shaftoli barglari ko‘k meva bargi deb, qulupnay barglari esa malina bargi deb aniqlandi. Bu holat model dala sharoitida barg shakli va rangidagi nozik farqlarni, shuningdek kasallikning boshlang‘ich bosqichidagi kichik belgilarni yetarli darajada ajrata olmasligini ko‘rsatadi.

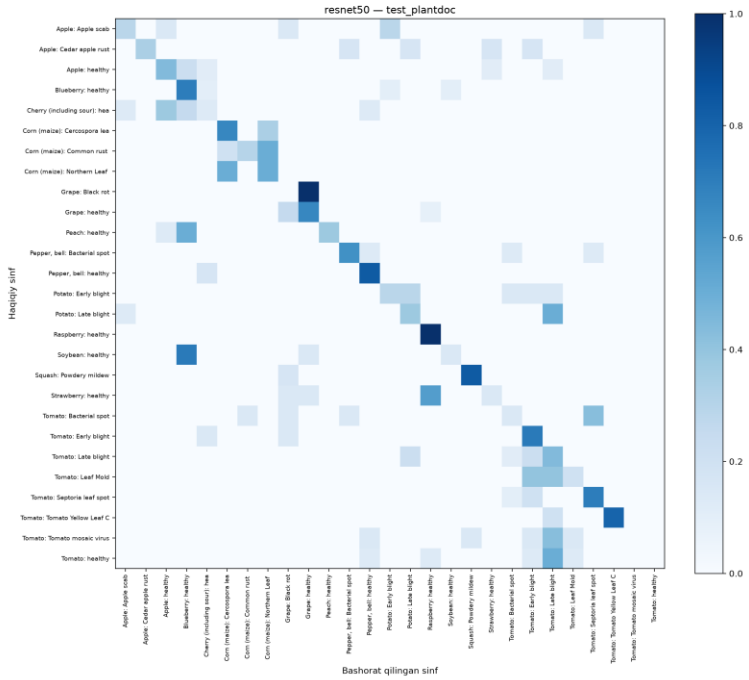

5-rasm. ResNet50 modelining PlantDoc tasvirlaridagi xatoliklar matritsasi (qatorlar bo‘yicha normallashtirilgan)

Manba: muallif tomonidan o‘tkazilgan tajribalar natijasi

Muhokama

Olingan natijalar laboratoriya to‘plamidagi yuqori aniqlik modelning real sharoitdagi ishonchliligini kafolatlamasligini tasdiqlaydi. PlantVillage tasvirlarida modellar orasidagi farq deyarli sezilmaydi, chunki bu to‘plamda vazifa nisbatan oson: har bir tasvirda markazda joylashgan bitta barg, bir xil fon va yoritilganlik mavjud.

Bunday sharoitda model kasallik belgilari bilan bir qatorda fon va suratga olish sharoitiga xos tasodifiy belgilarni ham o‘zlashtirib oladi [14, 15]. Dala tasvirlarida bu belgilar yo‘qoladi va modelning haqiqiy umumlashtirish qobiliyati namoyon bo‘ladi.

Arxitekturalar orasidagi farqlarni talqin qilishda dala test to‘plamining kichikligini hisobga olish lozim. 236 ta tasvirda 35 % atrofidagi aniqlik uchun 95 % ishonch oralig‘i taxminan ±6 foiz punktni tashkil etadi (3-rasmdagi kesmalar). Masalan, eng yaxshi natija bergan ResNet50 uchun bu oraliq 31,8–44,0 %, VGG16 uchun esa 23,0–34,5 % ga teng. Demak, VGG16 boshqa modellardan yaqqol ortda qolgan bo‘lsa-da, qolgan yettita model orasidagi 1–4 foiz punktli farqlar statistik jihatdan ishonchli emas. ImageNet-21k va ImageNet-22k to‘plamlarida oldindan o‘qitilgan EfficientNetV2-S, ConvNeXt-T, Swin-T va ViT-S/16 modellari faqat ImageNet-1k to‘plamida o‘qitilgan ResNet50 modelidan ustun kelmadi, ya’ni oldindan o‘qitish to‘plamining kattaligi dala sharoitidagi barqarorlikni o‘z-o‘zidan ta’minlamadi. Parametrlar soni va dala aniqligi o‘rtasida to‘g‘ridan-to‘g‘ri bog‘liqlik kuzatilmadi. Bu arxitekturani tanlashda faqat model hajmiga emas, balki uning tuzilishi va oldindan o‘qitish sharoitiga ham e’tibor berish zarurligini ko‘rsatadi.

Tadqiqotning ayrim cheklovlari ham mavjud. PlantDoc to‘plami nisbatan kichik va uning sinflari PlantVillage sinflarining faqat bir qismi bilan mos keladi. Har bir model bitta tasodifiy boshlang‘ich qiymat bilan o‘qitildi. Shuningdek, PlantDoc tasvirlari internet manbalaridan olingan, shuning uchun ular respublikamiz dalalaridagi sharoitni to‘liq aks ettirmaydi. Keyingi tadqiqotlarda mahalliy sharoitda olingan tasvirlar to‘plamini shakllantirish, shuningdek fonni ajratish va attention mexanizmlarini qo‘llash orqali modellarning dala sharoitidagi barqarorligini oshirish rejalashtirilgan.

Xulosa

Maqolada ekin kasalliklarini barg tasvirlari asosida aniqlash uchun sakkizta zamonaviy neyron tarmoq arxitekturasi yagona o‘qitish protokoli asosida qiyosiy baholandi. Laboratoriya tasvirlarida barcha arxitekturalar 99,7 % dan yuqori aniqlikka erishdi va ular orasidagi farq ahamiyatsiz bo‘ldi. Dala tasvirlarida esa aniqlik 28,4–37,7

% gacha tushib, laboratoriya natijalariga nisbatan 62,0–71,4 foiz punktga pasaydi. Eng yaxshi natijani ResNet50 arxitekturasi ko‘rsatdi, biroq VGG16 dan tashqari modellar orasidagi farq statistik ishonch oralig‘i doirasida qoldi. Olingan natijalar ekin kasalliklarini aniqlash tizimlarini ishlab chiqishda modellarni albatta dala sharoitidagi tasvirlarda ham baholash zarurligini ko‘rsatadi. Natijalar muallif tomonidan ishlab chiqilayotgan gibrid algoritm uchun tayanch (baseline) ko‘rsatkichlar sifatida xizmat qiladi.

Foydalanilgan adabiyotlar

1. FAO, IPPC Secretariat. Scientific review of the impact of climate change on plant pests. – Rome: FAO, 2021.

2. O‘zbekiston Respublikasi Prezidentining 2024-yil 14-oktabrdagi “Sun’iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasini tasdiqlash to‘g‘risida”gi PQ-358-son qarori. https://lex.uz/docs/-7158604

3. Deng J., Dong W., Socher R., Li L.-J., Li K., Fei-Fei L. ImageNet: A large-scale hierarchical image database // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2009. – P. 248–255.

4. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems. – 2012. – Vol. 25. – P. 1097–1105.

5. Sladojevic S., Arsenovic M., Anderla A., Culibrk D., Stefanovic D. Deep neural networks based recognition of plant diseases by leaf image classification // Computational Intelligence and Neuroscience. – 2016. – Art. 3289801.

6. Hughes D.P., Salathé M. An open access repository of images on plant health to enable the development of mobile disease diagnostics // arXiv:1511.08060. – 2015.

7. Mohanty S.P., Hughes D.P., Salathé M. Using deep learning for image-based plant disease detection // Frontiers in Plant Science. – 2016. – Vol. 7. – Art. 1419.

8. Ferentinos K.P. Deep learning models for plant disease detection and diagnosis // Computers and Electronics in Agriculture. – 2018. – Vol. 145. – P. 311–318.

9. Too E.C., Yujian L., Njuki S., Yingchun L. A comparative study of fine-tuning deep learning models for plant disease identification // Computers and Electronics in Agriculture. – 2019. – Vol. 161. – P. 272–279.

10. Barbedo J.G.A. Factors influencing the use of deep learning for plant disease recognition // Biosystems Engineering. – 2018. – Vol. 172. – P. 84–91.

11. Singh D., Jain N., Jain P., Kayal P., Kumawat S., Batra N. PlantDoc: A dataset for visual plant disease detection // Proceedings of the 7th ACM IKDD CoDS and 25th COMAD. – 2020. – P. 249–253.

12. Ramcharan A., Baranowski K., McCloskey P., Ahmed B., Legg J., Hughes D.P. Deep learning for image-based cassava disease detection // Frontiers in Plant Science. – 2017. – Vol. 8. – Art. 1852.

13. Thapa R., Zhang K., Snavely N., Belongie S., Khan A. The Plant Pathology Challenge 2020 data set to classify foliar disease of apples // Applications in Plant Sciences. – 2020. – Vol. 8, № 9. – Art. e11390.

14. Torralba A., Efros A.A. Unbiased look at dataset bias // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2011. – P. 1521–1528.

15. Geirhos R., Jacobsen J.-H., Michaelis C., Zemel R., Brendel W., Bethge M., Wichmann F.A. Shortcut learning in deep neural networks // Nature Machine Intelligence. – 2020. – Vol. 2. – P. 665–673.

16. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // International Conference on Learning Representations (ICLR). – 2015.

17. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 770–778.

18. Howard A., Sandler M., Chu G., Chen L.-C., Chen B., Tan M., et al. Searching for MobileNetV3 // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). – 2019. – P. 1314–1324.

19. Tan M., Le Q.V. EfficientNet: Rethinking model scaling for convolutional neural networks // Proceedings of the 36th International Conference on Machine Learning (ICML). – 2019. – P. 6105–6114.

20. Tan M., Le Q.V. EfficientNetV2: Smaller models and faster training // Proceedings of the 38th International Conference on Machine Learning (ICML). – 2021. – P. 10096–10106.

21. Liu Z., Mao H., Wu C.-Y., Feichtenhofer C., Darrell T., Xie S. A ConvNet for the 2020s // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2022. – P. 11976–11986.

22. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., et al. An image is worth 16x16 words: Transformers for image recognition at scale // International Conference on Learning Representations (ICLR). – 2021.

23. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. Swin Transformer: Hierarchical vision transformer using shifted windows // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). – 2021. – P. 10012–10022.

24. Wightman R. PyTorch Image Models (timm). – GitHub repository, 2019. https://github.com/huggingface/pytorch-image-models

25. Loshchilov I., Hutter F. Decoupled weight decay regularization // International Conference on Learning Representations (ICLR). – 2019.