QISHLOQ XO‘JALIK EKINLARI KASALLIKLARINI TASVIRLAR ASOSIDA ANIQLASHDA KONVOLYUTSION NEYRON TARMOQLARNING QO‘LLANILISHI: MUAMMOLAR VA ISTIQBOLLAR

Orazimbetov Akbarali Artikbayevich, magistrant

Xudayberdiyev M.X., t.f.d., professor

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti

Annotatsiya. *Tezisda qishloq xo‘jalik ekinlari kasalliklarini barg tasvirlari asosida avtomatik aniqlashda konvolyutsion neyron tarmoqlarni qo‘llash bo‘yicha xorijiy tadqiqotlar tahlil qilingan. Laboratoriya sharoitida olingan ma’lumotlar to‘plamlarida erishilgan yuqori aniqlik bilan haqiqiy dala sharoitidagi natijalar o‘rtasidagi katta farq ko‘rsatib berilgan. Ushbu farqning sabablari va uni kamaytirish yo‘nalishlari asoslangan.*

Kalit so‘zlar: *konvolyutsion neyron tarmoq, chuqur o‘qitish, o‘simlik kasalliklari, tasvirlarni tanib olish, ko‘chirib o‘qitish, PlantVillage, PlantDoc.*

Abstract. *The paper reviews studies on the use of convolutional neural networks for automatic detection of crop diseases from leaf images. It shows the large gap between the high accuracy reported on laboratory datasets and the results obtained on images taken in real field conditions, and discusses the causes of this gap and the directions for reducing it.*

Keywords: *convolutional neural network, deep learning, plant diseases, image recognition, transfer learning, PlantVillage, PlantDoc.*

Kirish

Oziq-ovqat xavfsizligini ta’minlash bugungi kunda dunyo miqyosidagi eng dolzarb masalalardan biri bo‘lib qolmoqda. FAO huzuridagi O‘simliklarni himoya qilish xalqaro konvensiyasi kotibiyati ma’lumotlariga ko‘ra, har yili jahon ekin mahsulotlarining 40 foizigacha qismi zararkunanda va kasalliklar ta’sirida yo‘qotiladi, o‘simlik kasalliklari esa jahon iqtisodiyotiga yiliga 220 milliard AQSh dollaridan ortiq zarar yetkazadi [1]. Kasallikni erta va to‘g‘ri aniqlash hosil yo‘qotilishini kamaytirishning eng samarali yo‘li hisoblanadi. Biroq bu ish hozircha asosan mutaxassisning ko‘z bilan kuzatuviga tayanadi. Katta maydonlarda bunday kuzatuvni muntazam olib borish qiyin, malakali fitopatologlar esa har bir xo‘jalikda mavjud emas.

So‘nggi yillarda chuqur o‘qitish, xususan konvolyutsion neyron tarmoqlar (CNN) tasvirlarni tanib olishda yuqori natijalar ko‘rsatmoqda. Shu sababli ularni barg fotosurati orqali kasallikni aniqlashda qo‘llash faol o‘rganilmoqda. Mazkur ishning maqsadi ushbu yo‘nalishdagi asosiy tadqiqotlarni tahlil qilish, ularning amaliyotda qo‘llanilishiga to‘sqinlik qilayotgan muammolarni aniqlash va istiqbolli yechimlarni belgilashdan iborat.

Asosiy qism

Dastlabki ishlarda kasallik belgilari, ya’ni dog‘larning rangi, shakli va teksturasi tadqiqotchi tomonidan qo‘lda ajratilgan va klassik mashinali o‘qitish usullari yordamida klassifikatsiyalangan. Bunday yondashuv har bir yangi ekin yoki kasallik uchun belgilarni qayta loyihalashni talab qilgan. CNN esa belgilarni bevosita tasvirlarning o‘zidan o‘rganadi, shuning uchun u bu sohada asosiy vositaga aylandi. D.P. Hughes va M. Salathé tomonidan PlantVillage ochiq ma’lumotlar to‘plamining yaratilishi bu jarayonni ancha tezlashtirdi [2]. Ushbu yo‘nalishdagi ayrim muhim natijalar 1-jadvalda keltirilgan.

1-jadval. Barg tasvirlari asosida kasalliklarni aniqlash bo‘yicha ayrim tadqiqotlar natijalari

Muallif, yil	Ma’lumotlar to‘plami	Model	Aniqlik, %
Sladojevic va boshq., 2016 [4]	Internetdan to‘plangan tasvirlar, 13 kasallik sinfi	CaffeNet	96,3
Mohanty va boshq., 2016 [3]	PlantVillage, 54 306 tasvir, 38 sinf	GoogLeNet	99,35
Ferentinos, 2018 [5]	87 848 tasvir, 58 sinf	VGG	99,53
Too va boshq., 2019 [7]	PlantVillage, 38 sinf	DenseNet-121	99,75
Singh va boshq., 2020 [6]	PlantDoc dala tasvirlari (PlantVillage’da o‘qitilgan model)	VGG16	15,08

Jadvaldan ko‘rinib turibdiki, laboratoriya tasvirlarida o‘qitilgan va sinalgan modellar 96–99 foizdan yuqori aniqlikka erishgan [3–5, 7]. Ammo bu natijalarni amaliyotga to‘g‘ridan-to‘g‘ri ko‘chirib bo‘lmaydi. PlantVillage tasvirlari bir xil fonda, yaxshi yoritilgan holda va har bir rasmda bitta barg bo‘ladigan qilib olingan. Dala tasvirlarida esa fon murakkab bo‘ladi: tuproq, boshqa barglar, qo‘l yoki soya ko‘rinib turadi, yorug‘lik ham bir tekis tushmaydi (1-rasm).

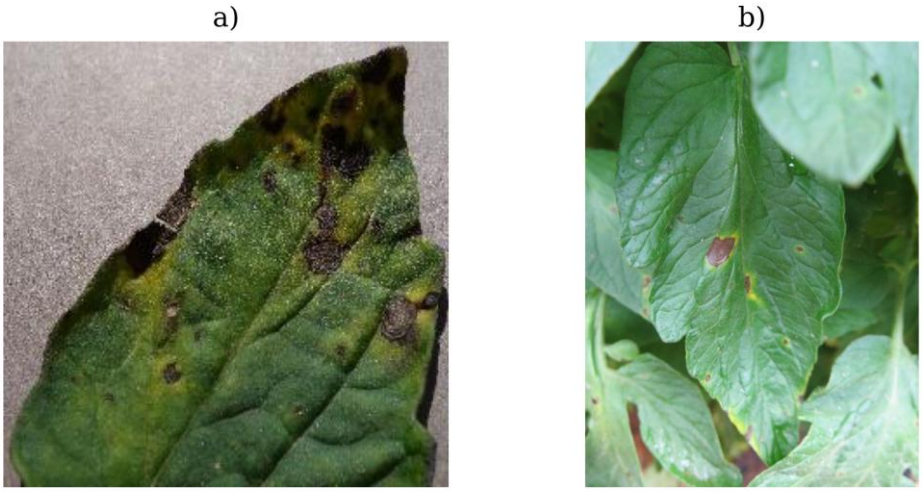

1-rasm. Pomidor bargidagi alternarioz (Early blight): a) laboratoriya tasviri, PlantVillage [2]; b) dala tasviri, PlantDoc [6]

Natijada model kasallik belgilari bilan birga fon va suratga olish sharoitini ham “yodlab” oladi. S.P. Mohanty va hammualliflar o‘z modellarini boshqa manbalardan olingan tasvirlarda sinaganda aniqlik 99,35 foizdan 31,4 foizgacha pasaygan [3]. D. Singh va hammualliflar tuzgan PlantDoc to‘plamida esa PlantVillage’da o‘qitilgan VGG16 modeli atigi 15,08 foiz aniqlik ko‘rsatgan [6]. Bu farq 2-rasmda yaqqol ko‘rinadi.

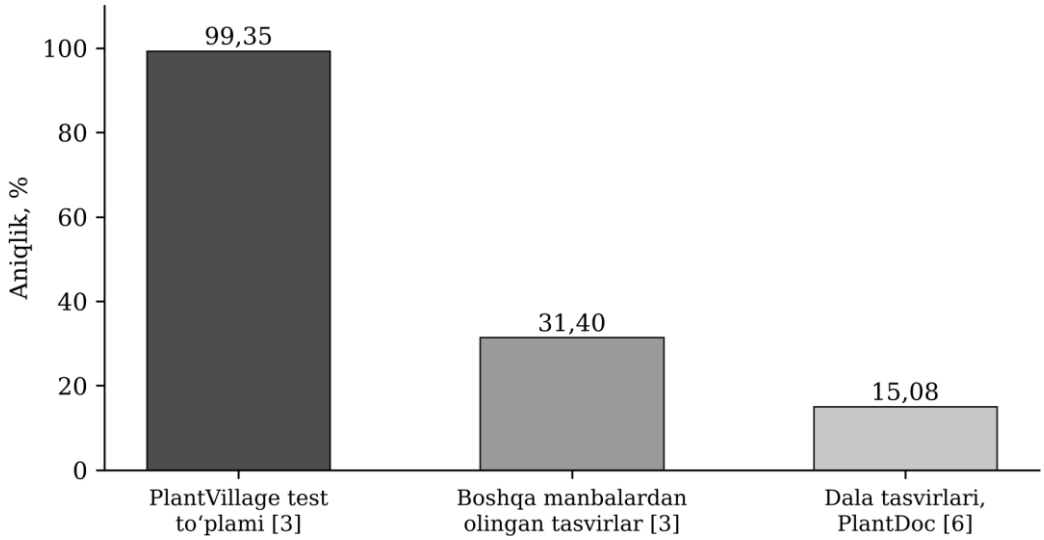

2-rasm. Laboratoriya tasvirlarida o‘qitilgan modellarning turli test to‘plamlaridagi aniqligi

Manba: [3] va [6] ma’lumotlari asosida muallif tomonidan tuzilgan

J.G.A. Barbedo ham chuqur o‘qitish natijalariga ma’lumotlar to‘plamining hajmi va xilma-xilligi, tasvirga olish sharoitlari hamda bir kasallik belgilarining turlicha namoyon bo‘lishi kuchli ta’sir ko‘rsatishini qayd etgan [8]. Bundan tashqari, aniqlik yuqori bo‘lgan

chuqur arxitekturalar ko‘p hisoblash resurslarini talab qiladi, bu esa ularni smartfonlarda ishlatishni qiyinlashtiradi. Modelning qarori ko‘pincha izohlanmaydi, shu sababli agronom tizimning nima asosida xulosa chiqarganini tekshira olmaydi. Mahalliy ekinlar, jumladan g‘o‘za kasalliklari bo‘yicha ochiq va yetarli hajmdagi ma’lumotlar to‘plamlarining yo‘qligi ham alohida muammo hisoblanadi [9].

Adabiyotlarda bu muammolarni yumshatishning bir necha yo‘nalishi ko‘rsatilgan. Ulardan birinchisi bargni fondan oldindan ajratish (segmentatsiya) bo‘lib, u modelning e’tiborini kasallik belgilariga qaratishga yordam beradi. Ikkinchisi attention mexanizmlaridan foydalanishdir. Masalan, CBAM moduli belgilar xaritasining eng muhim kanal va sohalarini kuchaytiradi [10]. Uchinchi yo‘nalish turli arxitekturalarning afzalliklarini birlashtiruvchi gibrid modellardir: bir tarmoq mayda mahalliy belgilarni, ikkinchisi bargning umumiy holatini yaxshiroq ushlaydi. Grad-CAM kabi vizual izohlash usullari esa model tasvirning qaysi qismiga qarab qaror qilganini ko‘rsatib, tizimga bo‘lgan ishonchni oshiradi [11]. Shuningdek, ImageNet kabi katta to‘plamlarda oldindan o‘qitilgan og‘irliklardan foydalanish (ko‘chirib o‘qitish) cheklangan hajmdagi ma’lumotlarda ham yuqori natijaga erishish imkonini beradi [7].

Xulosa

Tahlil shuni ko‘rsatadiki, konvolyutsion neyron tarmoqlar ekin kasalliklarini tasvirlar asosida aniqlashda laboratoriya sharoitida deyarli mukammal natijaga erishgan. Ammo haqiqiy dala sharoitida ularning aniqligi keskin pasayadi. Bu farqni kamaytirish uchun segmentatsiya, attention mexanizmlari va bir nechta arxitekturani birlashtiruvchi gibrid yondashuvlarni ishlab chiqish, shuningdek mahalliy sharoitda olingan tasvirlar to‘plamini shakllantirish zarur. Muallifning magistrlik dissertatsiyasi doirasidagi keyingi tadqiqotlari ana shu yo‘nalishda olib borilmoqda.

Foydalanilgan adabiyotlar

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

2. 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.

3. 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.

4. 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.

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

6. 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.

7. 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.

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

9. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: A survey // Computers and Electronics in Agriculture. – 2018. – Vol. 147. – P. 70–90.

10. Woo S., Park J., Lee J.-Y., Kweon I.S. CBAM: Convolutional block attention module // Proceedings of the European Conference on Computer Vision (ECCV). – 2018. – P. 3–19.

11. Selvaraju R.R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual explanations from deep networks via gradient-based localization // Proceedings of the IEEE International Conference on Computer Vision (ICCV). – 2017. – P. 618–626.