Taraqqiyot spektri
ILMIY JURNALI
Vol 2 № 11 2026

KOMPYUTER KO‘RISHI YORDAMIDA CHIQINDILARNI SARALASH PROTOTIPI

Yusupov Samandar Anvarovich

OXUS Universiteti katta o‘qituvchisi Toshkent 100208, O‘zbekiston

Samandar75781111@gmail.com

Serikbayeva Ayazhan Qayratova

OXUS University kompyuter ilimlari 501-26 guruh talabasi, 100105, O‘zbekiston

ayaukaqayratqizi@gmail.com

Tursunboyev Xaydarali To‘lqin o‘g‘li

OXUS University kompyuter ilimlari 501-26 guruh talabasi, 111500, O‘zbekiston

xaydaralitursunboyev1@gmail.com

Annotatsiya: Maqolada kompyuter ko‘rishi va chuqur o‘qitish usullaridan foydalanib maishiy chiqindilarni avtomatik aniqlash hamda saralash prototipining konseptual arxitekturasi taklif etiladi. Tizim kamera orqali olingan tasvirni dastlabki qayta ishlash, neyron tarmoq yordamida chiqindi sinfini aniqlash, ishonchlilik chegarasini tekshirish va mikrokontroller orqali mexanik yo‘naltirish bosqichlaridan iborat. Tadqiqotning metodik qismi ilmiy adabiyotlar tahlili, statistik ma’lumotlarni qiyoslash va prototipni kelgusida sinash uchun takrorlanadigan tajriba protokolini ishlab chiqishga asoslangan. UNEP hisobotida global maishiy qattiq chiqindilar hajmi 2023-yilda 2,1

milliard tonna bo‘lgani va 2050-yilga kelib 3,8 milliard tonnaga yetishi prognoz qilingani keltiriladi. Ilmiy maqolalarda ResNet50V2 va ConvNeXt_V1 kabi modellar turli ma’lumotlar to‘plamlarida yuqori tasniflash ko‘rsatkichlarini namoyish etgan. Ushbu ko‘rsatkichlar taklif qilinayotgan prototipning tajriba natijalari emas, balki adabiyotlarda e’lon qilingan natijalardir. Maqolada prototip uchun olti sinfli tasniflash sxemasi, baholash mezonlari va fizik sinov rejasi bayon qilinadi. Real qurilmada olingan aniqlik va saralash tezligi bo‘yicha natijalar alohida tajriba o‘tkazilgandan keyin kiritilishi lozim.

Kalit so‘zlar: kompyuter ko‘rishi, chiqindilarni saralash, sun’iy intellekt, CNN, transfer learning, ResNet, OpenCV, TensorFlow, avtomatlashtirish, ekologik texnologiyalar.

Abstract: This paper proposes a conceptual prototype architecture for automatic household waste recognition and sorting using computer vision and deep learning. The system includes image acquisition, preprocessing, waste-class prediction, confidence-threshold checking, and mechanical routing through a microcontroller. The methodology combines a review of scientific literature, comparison of published statistics, and a reproducible experimental protocol for future prototype testing. According to the United Nations Environment Programme, global municipal solid waste generation reached approximately 2.1 billion tonnes in 2023 and is projected to reach 3.8 billion tonnes by 2050. Published studies report high classification performance for models such as ResNet50V2 and ConvNeXt_V1 on their respective datasets. These published results must not be interpreted as experimental results of the prototype proposed in this paper. The paper defines a six-class waste taxonomy, evaluation metrics, and a physical testing plan. Actual accuracy and sorting-throughput results should be added only after experiments have been conducted on the implemented device.

Keywords: computer vision, waste sorting, artificial intelligence, CNN, transfer learning, ResNet, OpenCV, TensorFlow, automation, environmental technology.

Kirish: Chiqindilarni boshqarish va qayta ishlashga yaroqli materiallarni ajratish ekologik barqarorlik bilan bog‘liq muhim vazifalardan biridir. Aholi sonining o‘sishi, urbanizatsiya va iste’mol hajmining ortishi maishiy chiqindilar oqimining ko‘payishiga olib keladi. UNEPning Global Waste Management Outlook 2024 hisobotida global maishiy qattiq chiqindilar miqdori 2023-yilda 2,1 milliard tonnani tashkil etgani, amaldagi tendensiyalar davom etsa, 2050-yilda 3,8 milliard tonnaga yetishi prognoz qilingan.

Chiqindilarni qayta ishlash samaradorligi ularni yig‘ishdan oldin yoki qayta ishlash liniyasining dastlabki bosqichida to‘g‘ri saralashga ham bog‘liq. Qo‘lda saralashda operator mehnati talab etiladi; materiallar ifloslangan, ezilgan yoki bir-birini to‘sib turgan holatlarda tasniflash murakkablashadi. Kompyuter ko‘rishi kamera tasvirlaridan vizual belgilarni ajratib, materiallarni avtomatik tasniflash imkonini beradi.

Lu va Chenning 2022-yildagi tanqidiy sharhida kompyuter ko‘rishiga asoslangan chiqindi saralash tadqiqotlarida an’anaviy xususiyat ajratish usullaridan chuqur o‘qitish usullariga siljish kuzatilgani, biroq ko‘plab ishlar soddalashtirilgan muhit va maxsus yig‘ilgan ma’lumotlardan foydalangani qayd etilgan. Bu holat laboratoriya aniqligi bilan real saralash liniyasidagi samaradorlikni farqlash zarurligini ko‘rsatadi.

Tadqiqot maqsadi — kamera, tasvirni qayta ishlash moduli, neyron tarmoq va mexanik yo‘naltirish qurilmasini birlashtiruvchi chiqindilarni saralash prototipining ilmiy-texnik arxitekturasini ishlab chiqish hamda uni baholash uchun metodikani belgilash.

Tadqiqot vazifalari: chiqindilarni tasniflash sinflarini aniqlash; mos kompyuter ko‘rishi modelini tanlash mezonlarini belgilash; apparat va dasturiy modullar o‘zaro ishlashini tavsiflash; model sifatini baholash metrikalarini tanlash; real qurilma sinovlari uchun tajriba protokolini ishlab chiqish.

Maqolaning taklif etilayotgan ilmiy-amaliy hissasi — tasniflash natijasini ishonchlilik chegarasi bilan tekshirish va noaniq obyektni majburiy ravishda asosiy saralash oqimiga kiritmasdan, alohida tekshiruv bo‘limiga yo‘naltirishni nazarda tutuvchi modulli prototip arxitekturasidir. Bu yondashuvning samarasi amaliy sinov bilan tekshirilishi kerak.

Chiqindi sinflarini belgilash: Prototipning dastlabki versiyasi oltita sinfni ajratishga mo‘ljallanadi: plastik, qog‘oz, karton, metall, shisha va organik chiqindilar. Ushbu sinflar boshlang‘ich laboratoriya prototipi uchun tanlangan. Batareyalar, elektron chiqindilar, tibbiy yoki kimyoviy xavfli materiallar alohida xavfsizlik qoidalarini talab qilgani sababli mazkur dastlabki tasniflash doirasiga kiritilmaydi.

№	Sinf	Misollar	Saralash yo‘nalishi
1	Plastik	PET butilka, plastik idish	Plastik konteyner
2	Qog‘oz	Gazeta, daftar varag‘i	Qog‘oz konteyneri
3	Karton	Quti, karton qadoq	Karton konteyneri
4	Metall	Alyuminiy banka, metall buyum	Metall konteyneri
5	Shisha	Shisha butilka, banka	Shisha konteyneri
6	Organik	Meva-sabzavot va oziq-ovqat qoldig‘i	Organik konteyner

Tasvirni olish va dastlabki qayta ishlash: Kamera chiqindi obyektini belgilangan kuzatuv zonasida qayd etadi. Tasvir neyron tarmoq kirish o‘lchamiga moslashtiriladi, rang kanallari bir xil formatga keltiriladi va piksel qiymatlari model talabiga muvofiq normallashtiriladi. OpenCV kutubxonasi tasvirni o‘qish, kesish, o‘lchamini o‘zgartirish va kamera oqimini boshqarish uchun qo‘llanishi mumkin. Tasvirni qayta ishlash bosqichida obyektning muhim qismini yo‘qotib qo‘ymaslik uchun kesish va masshtablash parametrlari sinov orqali tanlanadi.

Neyron tarmoq modeli: Chiqindilar tasvirlarini tasniflash uchun konvolyutsion neyron tarmoq (CNN) yoki oldindan o‘qitilgan modeldan foydalanish mumkin. CNN qatlamlari tasvirdagi chetlar, tekstura, shakl va murakkab vizual belgilarni bosqichma-bosqich o‘rganadi. Transfer learning yondashuvida ImageNet kabi katta ma’lumotlar to‘plamida oldindan o‘qitilgan tarmoqning xususiyat ajratuvchi qatlamlari qayta ishlatiladi, so‘ng oxirgi tasniflagich yangi chiqindi sinflariga moslashtiriladi.

Ko‘rib chiqilishi mumkin bo‘lgan arxitekturalar: MobileNetV2 — hisoblash resurslari cheklangan qurilmalar uchun; ResNet50V2 — chuqurroq xususiyat ajratish uchun; EfficientNet yoki ConvNeXt — aniqlik va hisoblash xarajatlari muvozanatini o‘rganish uchun. Yakuniy model tanlovi faqat Accuracy bilan emas, balki model hajmi, bitta tasvirni qayta ishlash vaqti, xotira talabi va qurilmadagi barqaror ishlashi bilan ham belgilanadi.

Softmax funksiyasi sinflar bo‘yicha ehtimollik qiymatlarini hisoblashda ishlatilishi mumkin:

$$P(y = i \mid x) = \exp(z_i) / \Sigma_j \exp(z_j)$$

Bu yerda x — kiruvchi tasvir, z_i — modelning i-sinf uchun chiqish qiymati, y — bashorat qilingan sinf. Softmax qiymati model ishonchliligining amaliy indikatori sifatida ishlatilishi mumkin, biroq u har doim kalibrlangan haqiqiy ehtimollikni anglatmaydi.

Ma’lumotlar to‘plami va ajratish tartibi: O‘qitish uchun har bir sinf bo‘yicha turli yoritish, fon, masofa, kamera burchagi va obyekt holatlarini qamrab oluvchi tasvirlar yig‘ilishi kerak. Bir obyektning deyarli bir xil kadrlarini o‘qitish va test to‘plamlariga aralashtirish natijani sun’iy ravishda oshirishi mumkin. Shu sababli imkon qadar tasvirlar obyekt yoki yig‘ish sessiyasi bo‘yicha guruhlab ajratiladi.

Tajriba loyihasida ma’lumotlarni 70% o‘qitish, 15% validatsiya va 15% yakuniy test to‘plamlariga ajratish tavsiya etiladi. Bu maqolada taklif etilayotgan sinov dizayni bo‘lib, amalda yig‘ilgan ma’lumotlar soni yoki o‘tkazilgan tajriba natijasi emas. Sinflar soni muvozanatli bo‘lishi, test to‘plami esa model tanlashda ishlatilmasligi lozim.

Prototip arxitekturasi va ishlash algoritimi: Taklif etilayotgan qurilma apparat va dasturiy qismlardan tashkil topadi. Apparat qismiga kamera, hisoblash moduli (kompyuter yoki Raspberry Pi), mikrokontroller, servo motor yoki yo‘naltiruvchi mexanizm va alohida yig‘ish konteynerlari kiradi. Dasturiy qism Python, OpenCV va TensorFlow/Keras asosida ishlab chiqilishi mumkin.

Modul	Tavsiya etiladigan vosita	Vazifasi
Tasvir olish	USB kamera yoki Raspberry Pi Camera	Obyekt tasvirini olish
Tasvirni qayta ishlash	OpenCV	Kadrni tayyorlash va normallashtirish
Tasniflash	TensorFlow/Keras modeli	Chiqindi sinfini aniqlash
Boshqaruv	Arduino yoki mos mikrokontroller	Saralash buyrug‘ini qabul qilish

Mexanik qism	Servo motor va yo‘naltirgich	Obyektni tegishli konteynerga burish
Monitoring	Python jurnal/modul	Natija va xatolarni qayd etish

Ishlash ketma-ketligi:

Bosqich	Amal	Chiqish
1	Kamera obyektni qayd etadi	Raqamli tasvir
2	Tasvir oldindan qayta ishlanadi	Modelga mos tensor
3	CNN sinfni va ishonchlilik qiymatini hisoblaydi	Sinf + score
4	Ishonchlilik chegarasi tekshiriladi	Qabul qilish yoki qayta tekshirish
5	Mikrokontrollerga buyruq yuboriladi	Motor boshqaruvi
6	Mexanik yo‘naltirgich ishlaydi	Obyekt konteynerga tushadi
7	Natija jurnalga yoziladi	Sinov statistikasi

Ishonchlilik chegarasi τ oldindan belgilangan qiymat bo‘lib, modelning eng yuqori sinf balli ushbu chegaradan past bo‘lsa, obyekt “noma’lum/noaniq” deb belgilanadi. τ qiymati validatsiya to‘plamida noto‘g‘ri saralash va qayta tekshirish ulushi o‘rtasidagi muvozanat asosida tanlanadi. Uni sinovsiz 0,8 yoki boshqa aniq qiymat sifatida universal qoida deb belgilash to‘g‘ri emas.

Agar $\max_i P(y=i|x) \geq \tau$ *bo‘lsa — tanlangan sinfga yo‘naltirish; aks holda — alohida tekshiruv.*

Global chiqindilar hajmi: UNEPning 2024-yilgi hisobotida global maishiy qattiq chiqindilar hajmi 2023-yilda 2,1 milliard tonna bo‘lgani va 2050-yilda 3,8 milliard tonnaga yetishi prognoz qilingani qayd etilgan. Ushbu prognoz bo‘yicha nisbiy o‘sish quyidagicha hisoblanadi:

$$((3{,}8 - 2{,}1) / 2{,}1) \times 100\% \approx 81{,}0\%$$

Demak, UNEP prognozi bo‘yicha 2050-yildagi hajm 2023-yil ko‘rsatkichidan taxminan 81% yuqori bo‘lishi mumkin. Bu prognoz bo‘lib, kelajakdagi haqiqiy natija emas.

Ko‘rsatkich	Yil	Miqdor	Ma’lumot turi
Global maishiy qattiq chiqindi	2023	2,1 mlrd tonna	Hisobotdagi baho
Global maishiy qattiq chiqindi	2050	3,8 mlrd tonna	UNEP prognozi
Nisbiy o‘zgarish	2023–2050	≈81,0%	Muallif hisob-kitobi

Jahon bankining What a Waste 2.0 hisobotida 2016-yil uchun 2,01 milliard tonna chiqindi qayd etilgan va odatiy rivojlanish ssenariysida 2050-yil uchun 3,40 milliard tonna prognoz qilingan. Jahon banki va UNEP raqamlarini bitta prognoz qatori sifatida aralashtirmaslik kerak: ular turli hisobot yillari, metodologiya va ssenariylarga asoslangan.

Nashr qilingan tasniflash tajribalari: Alqarni va hammualliflarining 2023-yilda Sustainability jurnalida chop etilgan ishida CNN hamda oldindan o‘qitilgan DenseNet169, MobileNetV2 va ResNet50V2 modellari baholangan. Mualliflar o‘z ma’lumotlar to‘plamida ResNet50V2 uchun 98,95%, MobileNetV2 uchun 97,60%, DenseNet169 uchun 94,40% aniqlikni bildirgan. Bu raqamlar faqat mazkur maqoladagi tajriba sharoitiga taalluqli.

Model	E’lon qilingan Accuracy	Manba izohi
CNN	88,52%	2023-yilgi tadqiqot
DenseNet169	94,40%	2023-yilgi tadqiqot
MobileNetV2	97,60%	2023-yilgi tadqiqot
ResNet50V2	98,95%	2023-yilgi tadqiqot

Gurcan va Soylu tomonidan 2026-yil mart oyida Environmental Technology & Innovation jurnalida chop etilgan tadqiqotda 15 150 ta tasvir va 12 ta chiqindi sinfi ishlatilgan. 14 ta oldindan o‘qitilgan CNN modeli taqqoslangan; ConvNeXt_V1 modeli 96,95% test aniqligi va 95,72% F1-score ko‘rsatgan. Tadqiqotda yengilroq modellar, jumladan MobileNetV2, hisoblash xarajati va tezligi nuqtayi nazaridan ham ko‘rib chiqilgan.

Tadqiqot parametri	E’lon qilingan qiymat
Tasvirlar soni	15 150
Chiqindi sinflari	12
Taqqoslangan CNN modellari	14
Eng yuqori natija ko‘rsatgan model	ConvNeXt_V1
Test Accuracy	96,95%
F1-score	95,72%

Fotovvatikhah va hammualliflarining 2025-yildagi tizimli sharhida 97 dan ortiq ilmiy ish va 15 dan ortiq ochiq ma’lumotlar to‘plami tahlil qilingan. Mualliflar ma’lumotlar to‘plamlaridagi sinf nomutanosibligi, real muhitdagi o‘zgaruvchanlik va standartlashtirish muammolarini muhim cheklovlar sifatida ko‘rsatadi. Shu sababli turli maqolalardagi Accuracy qiymatlarini bir xil sharoitda olingan natijalar deb qabul qilish mumkin emas.

Lu va Chenning sharh maqolasida real sanoat sharoitiga o‘tishda soddalashtirilgan laboratoriya muhitlari, xususiy ma’lumotlar to‘plamlari va obyektlarning bir-birini to‘sishi kabi muammolarga e’tibor qaratilgan. Bu prototipni baholashda faqat tasvir tasniflash aniqligini emas, balki mexanik saralash muvaffaqiyatini ham alohida o‘lchash zarurligini asoslaydi.

Tasniflash sifatini baholash: Ko‘p sinfli tasniflashda har bir sinf uchun Precision, Recall va F1-score, shuningdek umumiy Accuracy hisoblanadi. Accuracy umumiy to‘g‘ri bashoratlar ulushini, Precision ijobiy deb belgilangan obyektlar ichida to‘g‘ri bo‘lganlar ulushini, Recall esa haqiqiy sinf obyektlaridan qanchasi topilganini ko‘rsatadi.

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

$$\text{Precision} = TP / (TP + FP)$$

$$\text{Recall} = TP / (TP + FN)$$

$$F1 = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall})$$

Bu yerda TP — to‘g‘ri ijobiy, TN — to‘g‘ri salbiy, FP — noto‘g‘ri ijobiy, FN — noto‘g‘ri salbiy holatlar. Ko‘p sinfli masalada ko‘rsatkichlar har bir sinf uchun alohida hisoblanadi; umumlashtirishda macro yoki weighted o‘rtacha qiymat turi aniq ko‘rsatilishi kerak.

Mexanik saralash samaradorligi: Tasniflash modelining aniqligi qurilmaning yakuniy saralash muvaffaqiyatiga teng emas. Mexanik qismda obyektning noto‘g‘ri tushishi, tiqilib qolishi, bir nechta obyektning bir vaqtda kirishi yoki motorning kechikishi mumkin. Shu sababli fizik saralash ko‘rsatkichi alohida hisoblanadi:

Saralash muvaffaqiyati = (to‘g‘ri konteynerga tushgan obyektlar / jami sinov obyektlari) × 100%

Shuningdek, bir daqiqada qayta ishlangan obyektlar soni, bitta obyektga sarflangan o‘rtacha vaqt, noaniq deb ajratilgan obyektlar ulushi va mexanik tiqilishlar soni qayd etilishi tavsiya etiladi.

№	Sinov ko‘rsatkichi	O‘lchash usuli	Namunaviy natija
1	Tasniflash Accuracy	To‘g‘ri bashoratlar ulushi	94,2%
2	Macro F1-score	Olti sinf F1 qiymatlarining o‘rtachasi	0,93
3	Fizik saralash muvaffaqiyati	To‘g‘ri konteynerga tushgan obyektlar ulushi	91,5%
4	O‘rtacha ishlov vaqti	Kadrdan yakuniy qarorgacha sarflangan vaqt	0,85 soniya
5	Unumdorlik	Bir daqiqada qayta ishlangan obyektlar soni	65 dona/minut
6	Noaniq obyektlar ulushi	Qo‘shimcha tekshiruvga yuborilgan obyektlar ulushi	4,8%

Tavsiya etiladigan tajriba tartibi: Birinchi bosqichda har bir sinf uchun tasvirlar turli sharoitlarda yig‘iladi. Ikkinchi bosqichda ma’lumotlar to‘plami guruhlab train/validation/test qismlariga ajratiladi. Uchinchi bosqichda kamida ikki model, masalan MobileNetV2 va ResNet50V2, bir xil test to‘plamida baholanadi. To‘rtinchi bosqichda tanlangan model hisoblash moduliga joylashtiriladi. Beshinchi bosqichda har bir sinfdan oldindan belgilangan miqdordagi obyektlar mexanik saralashdan o‘tkaziladi. Sinov davomida noto‘g‘ri saralash sabablari va qurilma ishlashidagi uzilishlar qayd etiladi.

Natijalarni ishonchli qilish uchun test to‘plamidagi har bir obyektning haqiqiy sinfi mustaqil ravishda belgilanishi, sinov sharoitlari hujjatlashtirilishi va tajribalar takrorlanishi

kerak. Natija bilan birga sinovlar soni (n), sana, qurilma konfiguratsiyasi, kamera turi, yoritish sharoiti va dasturiy model versiyasi berilishi lozim.

Muhokama: Adabiyotlarda e’lon qilingan natijalar chiqindi tasvirlarini CNN va transfer learning yordamida yuqori aniqlikda tasniflash mumkinligini ko‘rsatadi. Biroq 98,95% yoki 96,95% kabi ko‘rsatkichlarni taklif qilinayotgan prototipning natijasi sifatida ko‘rsatish ilmiy jihatdan noto‘g‘ri bo‘ladi: bu qiymatlar boshqa tadqiqotchilar tomonidan boshqa ma’lumotlar to‘plamlari va tajriba sharoitlarida olingan.

Amaliy prototip uchun model tanlashda aniqlik bilan birga hisoblash resursi ham muhim. Masalan, kichik hisoblash modulida ishlaydigan qurilma uchun MobileNet oilasidagi modelning tezligi va xotira sarfi ResNet yoki ConvNeXt kabi kattaroq arxitekturalarga nisbatan afzal bo‘lishi mumkin. Yakuniy qaror aynan ishlatiladigan qurilmada o‘lchangan kechikish va aniqlik natijalariga asoslanishi kerak.

Tizimning muhim cheklovi kamera tasviri materialning kimyoviy tarkibini bevosita aniqlamaydi. Masalan, tashqi ko‘rinishi o‘xshash yoki yorliq bilan qoplangan obyektlar xato tasniflanishi mumkin. Shu bois kelgusida RGB kamera bilan bir qatorda yaqin infraqizil (NIR) sensor, metall detektori yoki og‘irlik sensori kabi qo‘shimcha qurilmalarni integratsiya qilish o‘rganilishi mumkin. Bunday kengaytma alohida tajriba va xarajat tahlilini talab qiladi.

Taklif etilgan ishonchlilik chegarasi va alohida tekshiruv yo‘li xavfli yoki noaniq tasniflarni kamaytirishga qaratilgan. Biroq bu mexanizmning foydasi ham sinov orqali o‘lchanishi lozim: chegarani oshirish noto‘g‘ri saralashni kamaytirishi mumkin, lekin tekshiruvga yuboriladigan obyektlar ulushini oshiradi.

Xulosa: Maqolada kompyuter ko‘rishi asosida maishiy chiqindilarni aniqlash va saralash prototipining konseptual arxitekturasi ishlab chiqildi. Tizim kamera, tasvirni qayta ishlash moduli, CNN tasniflagichi, mikrokontroller va mexanik yo‘naltirish qurilmasidan

tashkil topishi taklif etildi. Dastlabki prototip uchun plastik, qog‘oz, karton, metall, shisha va organik chiqindilardan iborat olti sinfli tasniflash sxemasi belgilandi.

UNEP ma’lumotlariga asoslangan hisob-kitob global maishiy chiqindilar hajmi 2023-yildagi 2,1 milliard tonnadan 2050-yilda 3,8 milliard tonnagacha o‘sishi prognoz qilinayotganini, ya’ni taxminan 81 foizlik o‘sishni ko‘rsatadi. Ilmiy maqolalarda ResNet50V2 va ConvNeXt_V1 kabi modellar yuqori tasniflash natijalarini namoyish etgan. Bu natijalar prototip uchun model tanlashga asos bo‘la oladi, ammo bevosita uning samaradorligini isbotlamaydi.

Tadqiqotning amaliy bosqichida mahalliy sharoitda tasvirlar to‘plamini shakllantirish, kamida ikki modelni bir xil test to‘plamida taqqoslash, ishonchlilik chegarasini validatsiya orqali tanlash va mexanik saralash muvaffaqiyatini alohida o‘lchash zarur. Kelgusidagi ishlar prototipni fizik yig‘ish, tajriba natijalarini statistik tahlil qilish va real chiqindi oqimida sinashga qaratiladi.

Foydalanilgan adabiyotlar:

1. United Nations Environment Programme. Global Waste Management Outlook 2024. UNEP, 2024. https://www.unep.org/en/publications/report/global-waste-management-outlook-2024 (murojaat sanasi: 16.11.2026).

2. Lu, W., Chen, J. Computer vision for solid waste sorting: A critical review of academic research. Waste Management, 2022, Vol. 142, pp. 29–43.

https://doi.org/10.1016/j.wasman.2022.02.009.

3. Kaza, S., Yao, L. C., Bhada-Tata, P., Van Woerden, F. What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050. World Bank, 2018. https://doi.org/10.1596/978-1-4648-1329-0.

4. Deep Learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management. Sustainability, 2023, Vol. 15(14), Article 11138. https://doi.org/10.3390/su151411138.

5. Gurcan, F., Soylu, A. Automated waste classification for smart recycling: A multi-class CNN approach with transfer learning and pre-trained models. Environmental Technology & Innovation, 2026, Vol. 41, Article 104673. https://doi.org/10.1016/j.eti.2025.104673.

6. Fotovvatikhah, F., Ahmedy, I., Md Noor, R., Munir, M. U. A Systematic Review of AI-Based Techniques for Automated Waste Classification. Sensors, 2025, Vol. 25(10), Article 3181. https://doi.org/10.3390/s25103181.