



ӘОЖ 004.932.4

ҒТАХА 28.23.15

https://doi.org/10.53364/24138614_2026_42_3_13

Д.Ж.Кайбасова¹, А.Ш.Сұлтан^{1*}
¹Astana IT University, Астана, Қазақстан

*E-mail: 255734@astanait.edu.kz

БЕЙНЕЛЕРДЕГІ ШУЛАРДЫ БАСУ ӘДІСТЕРІ: ҚАЛДЫҚТАРДЫ СҰРЫПТАУДЫҢ АВТОМАТТАНДЫРЫЛҒАН ЖҮЙЕЛЕРІНДЕ НЫСАНДАРДЫ ТАҢУ ДӘЛДІГІН АРТТЫРУ

Аңдатпа. Нысандарды автоматтандырылған тану жүйелері өнеркәсіпте, робототехникада және экологиялық мониторингте кеңінен қолданылады, ал қалдықтарды сұрыптаудың интеллектуалды жүйелері аталған салалардың ішіндегі ең өзекті бағыттардың бірі болып табылады. Дегенмен, кескіндерді алдын ала өңдеу сапасы, әсіресе шуды басу кезеңі, тану дәлдігіне тікелей әсер ететіндігіне қарамастан, әдебиетте қалдықтарды сұрыптау контекстіндегі әр түрлі шудан азайту әдістерінің жүйелі салыстырмалы талдауы жеткіліксіз қарастырылған. Бұл пилоттық зерттеуде аталған олқылықтың орнын толтыруға бағытталған бастапқы қадам ретінде кескіндерді шуылдан тазартудың алты түрлі әдісі бірыңғай эксперименттік тәжірибеде салыстырылды: Гаусс сүзгісі, медиана сүзгісі, шекараларды бейімді сақтаумен гибриді әдіс, модификацияланған бейімді медиана сүзгісі (AMF+MDBMF) және алдын ала оқытусыз DnCNN нейрожелілік әдісі. Тәжірибелік база Kaggle TrashNet деректер жиынтығынан үш сыныпты (пластик, шыны, металл) қамтитын 15 репрезентативті түрлі-түсті бейнеден тұрды. Үш түрлі шуыл жасанды түрде қосылды: Гаусс шуылы ($\sigma = 25$), «тұз бен бұрыш» импульстік шуылы ($p = 5\%$) және Пуассон шуылы. Сапаны бағалау үшін бес метрика (PSNR, SSIM, MSE, MAE, EPI) және параметрлік емес статистикалық маңыздылық сынақтары (Уилкоксон белгілі рангтер сынағы, Коэн d коэффициенті) қолданылды. Қосымша, әдістердің есептеу күрделілігі (өңдеу уақыты) өлшенді. Нәтижелер медиана сүзгісінің барлық шуыл түрлерінде статистикалық маңызды артықшылықпен ($p < 0,01$) ең жоғары тиімділікті көрсеткенін дәлелдеді. Каскадты AMF+MDBMF әдісі импульстік шуылда жоғары тиімділікті көрсетті. Алдын ала оқытылмаған DnCNN нейрожелісі негативті нәтиже берді, бұл нейрожелілік модельдерді алдын ала оқытудың міндеттілігін растайды. Зерттеудің ғылыми жаңалығы – TrashNet деректер жиынтығында үш классқа жататын денойзинг әдістерін бірыңғай эксперименттік протоколда салыстыру әдіснамасын әзірлеуде. Алынған пилоттық нәтижелер қалдықтарды сұрыптаудың автоматтандырылған жүйелерінің алдын ала өңдеу блогын жобалау кезінде бағдар бере алады және болашақта толық TrashNet деректер жиынында (2527 бейне) кеңейтілуі тиіс.

Түйін сөздер: бейнелерді шуылдан тазарту, Гаусс шуылы, импульстік шуыл, нысандарды тану, медиана сүзгісі, гибриді сүзгілеу әдістері, статистикалық маңыздылық, PSNR, SSIM, TrashNet.

Кіріспе.

Компьютерлік көру медициналық бейнелеу, қауіпсіздік жүйелері, өнеркәсіптік ортадағы сапаны бақылау және автономды робототехника сияқты салаларға терең енген [1, 2]. Осы бағыттардың арасында қатты тұрмыстық қалдықтарды автоматтандырылған сұрыптау соңғы жылдары экологиялық міндеттердің күшеюіне және циркулярлық экономика концепциясының дамуына байланысты ерекше өзектілікке ие болды [3, 4, 5, 6]. Пластикалық бөтелкелерді, металл банкаларды және шыны ыдыстарды нақты уақыт режимінде ажырата алатын интеллектуалды жүйелер өндіріске жаппай енгізілуде, бірақ олардың сапасы кіріс деректерінің, яғни цифрлық кескіндердің сапасына тікелей тәуелді.

Іс жүзінде өнеркәсіптік шарттарда алынған кескіндер мінсіз болмайды. Конвейер таспасының діріл, біркелкі емес жарықтандыру, сенсорда жинақталған шаң, төмен жарық кезінде ISO мәнінің артуы және деректерді беру кезіндегі артефактілер – осының барлығы кескіндегі шуылдың пайда болуына әкеледі [7, 8]. Шуылдың болуы кейінгі классификация дәлдігін айтарлықтай төмендетеді: тіпті заманауи терең конволюциялық желілер (CNN) шумен бұрмаланған кескіндерді өңдегенде 10–25%-ға қателесуі мүмкін [9, 10]. Осы себептен шуды басу (image denoising) қазіргі заманғы компьютерлік көру жүйелерінде маңызды алдын ала өңдеу кезеңі болып табылады.

Цифрлық кескіндердегі шуылды пайда болу себептері мен статистикалық сипаттамаларына байланысты үш негізгі түрге бөлуге болады [7, 11, 12]. **Гаусс шуылы** камера сенсорындағы электрондық шуылдың салдары болып табылады; ол қалыпты үлестірімге ие және төмен жарық немесе жоғары ISO мәндерінде күшейеді. **«Түз бен бұрыш»** импульстік шуылы кездейсоқ қара және ақ нүктелер түрінде көрінеді, яғни бұл сенсордың зақымдалу немесе деректерді беру қателіктерінің салдары. **Пуассон шуылы** жарықтың кванттық табиғатынан туындайды: жарықтығы жоғары аймақтарда шуыл қарқынды болады, бұл өнеркәсіптік камераларда жиі кездеседі [12].

Әдебиеттерге шолу.

Соңғы жылдары кескіндерді шуылдан тазарту бойынша зерттеулерді шартты түрде үш бағытқа бөлуге болады. *Бірінші бағыт:* классикалық кеңістіктік сүзгілерді (Гаусс, медиана, орташа, билатеральды) жетілдіру. Кауг және басқалар [7] жүргізген кешенді шолу классикалық сүзгілердің есептеу тиімділігі жоғары болғанымен, шуылдың әр түрі үшін бөлек реттеуді қажет ететіндігін көрсетеді. Sun [13] медиана мен орташа сүзгілердің Гаусс шуылындағы тиімділігін салыстырып, медиана сүзгісінің артықшылығын дәлелдеді, бірақ зерттеу тек бір шу түріне және синтетикалық қарапайым кескіндерге шектелген.

Екінші бағыт: бейімделгіш және гибриді әдістерді әзірлеу. Ullah және басқалар [11] AMF+MDBMF каскадтық сүзгісін ұсынды, ол импульстік шуыл тығыздығы 90%-ға дейін жеткенде де кескінді қалпына келтіруге қабілетті. Алайда автормен жүргізілген тәжірибелер тек медициналық кескіндерде орындалған, сонымен қатар Гаусс және Пуассон шуылдары талданбаған. Abdul Wadood пен Ghalib [14] бейсызықтық сүзгілерді астрономиялық кескіндерде салыстырды, бірақ нәтижелерді қалдықтарды сұрыптау контекстіне көшіру мүмкін емес, өйткені деректер сипаты түбегейлі ерекшеленеді.

Үшінші бағыт: терең оқытуға негізделген әдістер. Tian және басқалар [12], Elad және басқалар [10], Izadi және басқалар [9] жасаған шолулар DnCNN, FFDNet, Restormer сияқты заманауи нейрожелілік модельдердің PSNR метрикасы бойынша классикалық әдістерден 2–4 дБ-ға жоғары тиімділік көрсететінін дәлелдейді. Алайда бұл нәтижелер ірі көлемді жалпы мақсаттағы деректер жиындарында (BSD500, Set12, Urban100) алынған, сонымен қатар тиісті алдын ала оқытуды қажет етеді. Қалдықтарды сұрыптау бойынша жұмыстарда [2, 3, 4, 5, 6] негізінен классификациялық бөлік (YOLO, ResNet, EfficientNet) талданады, ал шуды басу қадамы егжей-тегжейлі қарастырылмайды немесе тек бір ғана сүзгі қолданылады.

Аталған әдебиеттерге шолудан мынадай олқылықтарды анықтауға болады: (1) қалдықтарды сұрыптау бойынша деректер жиынында (TrashNet) денойзинг әдістерінің

жүйелі салыстырмалы талдауы жоқ; (2) көптеген зерттеулер тек бір шу түрі бойынша орындалған, ал нақты өнеркәсіптік шарттарда бірнеше шу түрі бір мезгілде кездеседі; (3) шуды басу әдістерінің есептеу күрделілігі мен олардың кейінгі классификация дәлдігіне әсері бір зерттеу аясында сирек қарастырылады; (4) сапаны бағалау тек метрикалардың орташа мәндерімен шектеледі, статистикалық маңыздылық тестілері (Уилкоксон сынағы, Коэн d) сирек қолданылады.

Зерттеудің ғылыми жаңалығы келесіде:

1) қалдықтарды сұрыптау контекстіндегі денойзинг әдістерін салыстырудың бірыңғай эксперименттік протоколы әзірленді, ол үш түрлі шу түрін (Гаусс, импульстік, Пуассон), әр түрлі әдіс кластарын (классикалық, гибридті, нейрожелілік) және сапаны бағалаудың бес метрикасын біріктіреді;

2) бірінші рет TrashNet деректер жиынында 15 кескіннен тұратын репрезентативті таңдамада денойзинг әдістерінің тиімділігінің статистикалық маңыздылығы Уилкоксонның белгілі рангтер сынағы және Коэн d коэффициенті көмегімен бағаланды (пилоттық дизайн);

3) шуылдан тазарту әдістерінің есептеу күрделілігі (бір кескінді өңдеу уақыты) және олардың MobileNetV2 классификаторының дәлдігіне әсері бір зерттеу аясында бағаланды, бұл әдісті тәжірибеде таңдау бойынша негізделген ұсыныстар жасауға мүмкіндік береді.

Зерттеудің мақсаты – қайта өңделетін қалдықтардың кескіндерінде шуды басудың алты әдісінің тиімділігін салыстырмалы бағалау және әр түрлі шу түрлері үшін ең тиімді әдісті статистикалық маңыздылықпен анықтау. Қойылған міндеттер: (а) деректер жиынын дайындау және үш түрлі шуылды бақыланатын параметрлермен қосу; (б) алты сүзу әдісін бірыңғай протоколда жүзеге асыру және сынау; (в) сапа метрикалары бойынша нәтижелерді статистикалық талдау; (г) есептеу күрделілігі мен классификация дәлдігіне әсерін бағалау; (д) тәжірибелік қолдану үшін ұсыныстар жасау.

Зерттеу материалдары мен әдістері.

Тәжірибелік деректер жиынтығы

Тәжірибелер үшін жалпыға қолжетімді Kaggle TrashNet деректер жиынтығынан [3] үш сыныпты қамтитын 15 репрезентативті түрлі-түсті бейне таңдалды: пластик (500 бейне), шыны (500 бейне) және металл (500 бейне). Бұл пилоттық эксперимент болып табылады; шектеулі тарихи мысал ретінде толық деректер жиыны (2527 бейне) бойынша кеңейту болашақ зерттеулердің мақсаты болып табылады. Кескіндердің рұқсаттылығы 512×384 пиксель, JPEG форматында, RGB түс кеңістігінде. Кескіндер бақыланатын жарықтандыру жағдайларында, біркелкі ақ фонда түсірілген, бұл шуды басу әдістерінің таза қасиеттерін бағалауға мүмкіндік береді, яғни таза кескіндер референс ретінде қызмет етеді. Шағын бірақ сапалы бақыланатын таңдама әдістерді сапалық тұрғыдан ажыратуға және алдағы үлкен ауқымды зерттеулер үшін бағыт беруге жеткілікті.

Зерттеліп отырған сүзгілеу әдістеріне шолу

Зерттеуде үш әр түрлі сынып әдістеріне жататын алты сүзу әдісі іске асырылды: классикалық кеңістіктік сүзгілер (Гаусс, медиана), бейімделгіш және гибридті әдістер (адаптивті жиекті сақтайтын гибрид, AMF+MDBMF), терең оқытуға негізделген тәсіл (DnCNN). Барлық әдістер OpenCV 4.8.1, scikit-image 0.21.0 және PyTorch 2.0.1 кітапханалары арқылы Python 3.10 ортасында жүзеге асырылды.

Гаусс сүзгісі – сызықтық төмен жиілікті сүзгі. Кескін Гаусс сүзгісі (қалыпты үлестірілген) арқылы оралады, бұл орталыққа жақын орналасқан пикселдерге үлкен салмақ береді. Гаусс сүзгісі көбінесе шуды азайту үшін екі өлшемді сигналдарды (кескіндерді) өңдеу үшін сандық түрде қолданылады. Бұл сүзгі Гаусс шуды жоятын сызықтық тегістеу әсеріне ие және кескінді өңдеуде шуды азайтуда кеңінен қолданылады. Екі өлшемді Гаусс ядросы (1) өрнегімен анықталады [7, 14]:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (1)$$

мұндағы x және y – орталық ядродан көлденең және тік қашықтықтар, σ – тегістеу деңгейін анықтайтын стандартты ауытқу.

Эксперименттерде ядро өлшемі 5×5 , $\sigma = 1,0$ қолданылды. Бұл әдіс Гаусс шуын жоюда тиімді, бірақ шекаралар мен ұсақ бөлшектерді бұлдырлайды; импульстік шуылға іс жүзінде тиімсіз. Уақыттық күрделілігі: $O(N \cdot k^2)$, мұндағы N – пиксельдер саны, k – ядро өлшемі [13, 14].

Медиана сүзгісі – бұл орташа мәнді пайдаланбайтын сызықтық емес сүзгі, оның орнына әрбір пиксель сүзгі терезесіндегі барлық пикселдердің медианасымен ауыстырылады, бұл (2) теңдеуінде көрсетілген [7]:

$$\hat{f}(x, y) = \text{median}\{g(r, c) | (r, c) \in S_{xy}\} \quad (2)$$

мұндағы $S_{xy} - (x, y)$ нүктесінде орналасқан сүзгілеу терезесі. (x, y) нүктесіндегі пиксель мәні медиана есептеуіне де кіреді.

Медиана сүзгісінде терезе пішіні міндетті түрде шаршы болуы міндетті емес, арнайы сүзгі пішіндері кескіндегі сызықтық құрылымдар мен жиектерді сақтай алады, бұл оларды жобалау мен енгізуді күрделі етеді. Тәжірибелерде квадрат терезе 3×3 қолданылды. Медиана сүзгісі рангтік сүзгілер класының жеке жағдайы болып табылады және импульстік шуыл («тұз бен бұрыш») жағдайында ерекше тиімді, өйткені экстремалды мәндер (0 және 255) орташалау есебіне кіреді, бірақ медиана мәнін анықтамайды. Бұл сүзгі орталық пиксельдің мәнін көршілерінің реттелген тізбегінен алынған мәнмен ауыстырады. r ретті рангтік сүзгі ($1 \leq r \leq N$, мұндағы N – көршілес элементтер саны) алынған тізбектен r индексі бар элементті таңдайды және оның мәнін бастапқы кескіннің сүзілген пиксель мәні ретінде тағайындайды. Уақыттық күрделілігі: $O(N \cdot k^2 \cdot \log k)$.

Адаптивті жиекті сақтайтын гибриді әдіс – Гаусс және медианалық сүзгілердің салмақтық қосындысына негізделген әдіс [13, 14]. Әрбір пиксель үшін жергілікті градиент шамасы есептеледі, оның негізінде салмақ коэффициенті анықталады:

$$\hat{f}_{\text{hybrid}(x,y)} = w(x, y) * f_{\text{median}(x,y)} + (1 - w(x, y)) * f_{\text{gauss}(x,y)} \quad (3)$$

мұндағы $w(x, y) \in [0, 1]$ – Собель операторымен есептелген жергілікті градиент шамасына тең. Жиектерде (жоғары градиент) медианалық бөлік басым, ал біркелкі аймақтарда – Гаусс. Тәжірибелерде Гаусс компоненті үшін ядро 5×5 , $\sigma = 1,0$, медиана компоненті үшін терезе 3×3 қолданылды. Бұл әдіс екі сүзгінің артықшылықтарын біріктіреді: біркелкі шуды тегістейді және шекараларды сақтайды.

AMF+MDBMF каскадтық әдісі – Ullah және басқалардың [11] жұмысы бойынша іске асырылған екі сатылы әдіс. Бірінші саты – Adaptive Median Filter (AMF): пиксель мәні (0 немесе 255) жергілікті экстремум деп есептелсе, терезе өлшемі ұлғайтылады (3×3 -тен бастап 7×7 -ге дейін), әйтпесе медиана арқылы ауыстырылады. Екінші саты – Modified Decision-Based Median Filter (MDBMF): тек бірінші сатыда зақымдалған деп белгіленген пикселдер ғана өзгертіледі; егер пиксель экстремум болмаса, ол өзгеріссіз қалады. Бұл селективтілік таза аймақтарда қажетсіз тегістеуді жояды және импульстік шу тығыздығы жоғары болғанда да тиімді. Алгоритмдік қадамдар:

– 1-қадам: әр пиксель үшін S_{xy} терезесінде минимум, максимум және медиана есептелсін;

– 2-қадам: егер ағымдағы пиксель мәні ($\min$, $\max$) аралығында болса, ол шусыз деп есептеледі;

– 3-қадам: әйтпесе пиксель медианамен ауыстырылады; егер медиана да экстремум болса, терезе ұлғайтылады;

– 4-қадам: MDBMF-те қосымша шу карта (binary noise mask) пайдаланылады

DnCNN (алдын ала оқытусыз) – Zhang және басқалар ұсынған конволюциялық нейрондық желі [12, 15]. Архитектура 17 конволюциялық қабаттан тұрады (3×3 ядро, 64 сүзгі, ReLU активациясы, Batch Normalization), қалдық оқытуға (residual learning) негізделген: модель таза кескінді емес, шу компонентін болжайды, ол кейін шулы кескіннен алынады. Зерттеуде модель әдейі алдын ала оқытусыз қолданылды – бұл компоненттің бар-жоғы тиімді нейрожелілік шуды басу үшін жеткіліксіз екенін көрсету мақсатында жасалды. Бұл шешім практикалық тұрғыдан маңызды: көптеген қолданбалы инженерлер дайын модельдерді тиісті тюнингсіз пайдалануға тырысады, ал біздің тәжірибе мұндай тәсілдің қауіптерін көрнекі көрсетеді.

Қалпына келтіру сапасын бағалау көрсеткіштері

Шуды азайтудан кейін кескінді қалпына келтіру сапасын сандық бағалау үшін бес көрсеткіш пайдаланылды, олардың әрқайсысы нәтиженің әртүрлі аспектілерін көрсетеді [16, 17].

PSNR (*Peak Signal-to-Noise Ratio*) – децибелмен өлшенетін және әдетте логарифмдік шкала бойынша өрнектелетін сигнал-шу қатынасының шыңы. Ол түпнұсқа және қалпына келтірілген кескіндер арасындағы айырмашылық дәрежесін сандық түрде анықтайды. PSNR мәндерінің жоғары болуы қалпына келтіру сапасының жақсырақ екенін көрсетеді [16]:

$$PSNR = 10 \times \log_{10} \left(\frac{MAX_1^2}{MSE} \right) \quad (4)$$

мұндағы MAX_1^2 – пиксельдің максималды мүмкін мәні (мысалы, 8 биттік кескіндер үшін 255);

MSE – орташа квадраттық қате.

SSIM (*Structural Similarity Index*) – құрылымдық ұқсастық индексі (0-ден 1-ге дейін), пиксель деңгейіндегі айырмашылықтардан асып түседі және жарықтықты, контрастты және құрылымды ескереді. Бұл кескін сапасын бағалау метрикасы адамның қабылдауын имитациялайды және PSNR-ден айырмашылығы, SSIM кескіннің құрылымдық ерекшеліктерін ескереді [16]:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

мұндағы $\mu_x\mu_y$ – кескіннің орташа мәні, σ_x^2 , σ_y^2 – дисперсия, σ_{xy} – ковариация, C_1 , C_2 – тұрақтандырушы тұрақтылар.

MSE (*Mean Squared Error*) – түпнұсқа және қалпына келтірілген кескіндердің пиксельдері арасындағы квадраттық ауытқулардың орташа мәнін сипаттайды, орташа квадраттық қателік үлкен ауытқуларға да сезімтал келеді [17]:

$$MSE = \frac{1}{N} \sum_{i=1}^N (I_i - K_i)^2 \quad (6)$$

мұндағы I_i – түпнұсқа кескіннің пиксель мәні, K_i – өңделген пиксельдің кескін мәні, N – пиксельдердің жалпы саны.

MAE (*Mean Absolute Error*) – барлық пиксельдер үшін орташа абсолютті қатені есептеуге негізделген түпнұсқа және өңделген кескіндер арасындағы айырмашылықты

бағалау әдісі, MSE-мен салыстырғанда ол ауытқуларға сезімталдығы төмен, модель болжамдарының шынайы мәндерден орташа абсолютті ауытқуын өлшейді [17]:

$$MAE = \frac{1}{N} \sum_{i=1}^N |I_i - K_i| \quad (7)$$

мұндағы I_i , K_i , N – MSE-ге ұқсас.

Жиектерді сақтау индексі – бастапқы және өңделген кескіндердің Лаплас контурлық карталары арасындағы нормаланған корреляция ретінде есептелетін, нысандардың контурлары мен шекараларын сақтау үшін сүзу әдісінің мүмкіндігін бағалайтын метрика [17]:

$$EPI = \frac{\sum_i (\nabla I_i * \nabla K_i)}{\sum_i (\nabla I_i)^2} \quad (8)$$

мұндағы ∇I_i , ∇K_i – градиенттер (Собель операторы), I – бастапқы кескін, K – өңделген кескін.

Статистикалық талдау әдістері

Әдістер арасындағы айырмашылықтардың статистикалық маңыздылығын бағалау үшін *Уилкоксонның белгілі рангтер сынағы* (Wilcoxon signed-rank test) пайдаланылды. Бұл сынақ параметрлік емес болып табылады және метрикалардың қалыпты үлестірілуін талап етпейді, сонымен қатар шағын таңдамаларда ($N \geq 6$) сенімді жұмыс істейді [17], бұл біздің пилоттық зерттеудің контекстінде маңызды. Маңыздылық деңгейі $\alpha = 0,05$ ретінде белгіленді. Барлық р-мәндер 15 кескінге сәйкес келетін жұптасқан таңдамалар бойынша есептелді.

Эффект мөлшерін бағалау үшін Коэн d коэффициенті қолданылды:

$$d = \frac{(\mu_1 - \mu_2)}{\sigma_{pooled}}, \sigma_{pooled} = \sqrt{\frac{(\sigma_1^2 + \sigma_2^2)}{2}} \quad (9)$$

мұндағы Cohen бойынша: $|d| < 0,2$ – кіші, $0,2 \leq |d| < 0,5$ – орташа, $0,5 \leq |d| < 0,8$ – үлкен, $|d| \geq 0,8$ – өте үлкен эффект. Коэн d коэффициенті таңдама көлеміне тәуелді емес, ол метрикалардың таралу аумағындағы айырмашылықты сипаттайды, бұл шағын таңдамалар үшін аса құнды.

Әр метрика үшін орташа мән $\pm$ стандартты ауытқу ($\mu \pm \sigma$) есептелді. *Пилоттық таңдама көлемінің шектеулерін мойындай отырып*, біз есептелген р-мәндер мен d-мәндерін болашақ кеңейтілген зерттеу үшін бағыт-бағдар ретінде қарастырамыз; нәтижелердің сенімділігі толық TrashNet деректер жиынында расталуы тиіс.

Эксперименттік орта.

Барлық эксперименттер келесі есептеу платформасында жүргізілді: процессор Intel Core i7-11800H (2.30 ГГц, 8 ядро), оперативті жады 16 ГБ DDR4, видеокарта NVIDIA RTX 3060 (6 ГБ GDDR6, CUDA 11.8). Бағдарламалық қамтамасыз ету: Windows 11, Python 3.10.12, OpenCV 4.8.1, scikit-image 0.21.0, NumPy 1.24.3, SciPy 1.11.1, PyTorch 2.0.1+cu118. Барлық уақыт өлшеулері `time.perf_counter()` функциясы арқылы орындалды, 10 қайталау бойынша орташа алынды.

Тәжірибелік деректер жиынтығы және шу шығару процедурасы.

Тәжірибелік деректер жиынтығы жалпыға қолжетімді Kaggle TrashNet жинағынан [3] алынған 15 түрлі-түсті кескіннен тұрды. Үш нысан санаты пайдаланылды: пластик, шыны және металл. Рұқсаттылық 512×384 пиксель болды, бақыланатын жарықтандыру жағдайларында түсірілген.

Әрбір кескін үш түрлі шумен нашарлатылды. Нәтижесінде барлығы 45 шулы кескін пайда болды ($15 \text{ түпнұсқа} \times 3 \text{ шу түрі}$).

1-суретте әртүрлі σ мәндері үшін Гаусс шуы көрсетілген (5, 25, 50). Негізгі тәжірибелер үшін $\sigma = 25$ өнеркәсіптік бейнелеу жағдайларын нақты жуықтау ретінде тандалды.



1 сурет – Стандартты ауытқу параметрлері $\sigma = \{5, 25, 50\}$ болатын Гаусс шуы

2-суретте бастапқы мәні 5%-ға орнатылған, ықтималдығы 1%, 5% және 10% болатын «тұз бен бұрыш» шуы көрсетілген.



2 сурет – «Тұз бен бұрыш» импульстік шуы: $p = 1\%$ (әлсіз), $p = 5\%$ (орташа), $p = 10\%$ (күшті)

3-суретте орташа жарықтық аймақтарында айқын көрінетін, өзіне тән түйіршікті құрылымы бар Пуассон шуы көрсетілген.



3 сурет – Бастапқы кескін мен Пуассон шуы бар кескінді салыстыру

Барлық код OpenCV, NumPy және scikit-image көмегімен Python тілінде жазылған.

Нәтижелер және талқылау.

Барлық метрикалық мәндер деректер жиынындағы 15 сурет бойынша орташа мәндер болып табылады. PSNR және SSIM үшін $\mu \pm \sigma$ форматында берілген; MSE, MAE және EPI үшін орташа мәндер келтірілген (шағын таңдамада экстремум мәндерге сезімтал, дисперсияны түсіндіру қиын). 1, 2 және 3-кестелерде сәйкесінше Гаусс шуылы, импульстік шуыл және Пуассон шуылы үшін нәтижелер келтірілген.

1 кесте – Гаусс шуылын сүзу нәтижелері ($\sigma = 25$, $N = 15$, PSNR/SSIM: $\mu \pm \sigma$)

Әдіс	PSNR (дБ)	SSIM	MSE	MAE	EPI
Шулы кескін	$23,55 \pm 0,47$	$0,2774 \pm 0,043$	288,73	13,49	0,632
Гаусс	$30,70 \pm 1,04$	$0,8276 \pm 0,030$	56,86	5,53	0,765
Медиана	$31,68 \pm 1,03$	$0,8536 \pm 0,029$	45,36	5,00	0,832
Гибридті	$31,23 \pm 0,87$	$0,8448 \pm 0,028$	49,87	5,15	0,815
AMF+MDBMF	$29,18 \pm 1,06$	$0,7013 \pm 0,031$	80,77	6,50	0,737
DnCNN (оқытусыз)	$21,34 \pm 1,73$	$0,2779 \pm 0,044$	514,13	17,06	0,632

Ескертпе: ең жақсы нәтижелер қалың қаріппен белгіленген.

Гаусс шуылын сүзу жағдайында медиана сүзгісі барлық бес метрика бойынша ең жақсы нәтижелерді көрсетті (PSNR = $31,68 \pm 1,03$ дБ; SSIM = $0,854 \pm 0,029$). Гибридті әдіс жақын нәтижелерге қол жеткізді (PSNR = $31,23 \pm 0,87$ дБ), бірақ Уилкоксон сынағы бойынша айырмашылық статистикалық маңызды ($p = 0,0047$). Гаусс сүзгісі үшінші орынды иеленді (PSNR = $30,70 \pm 1,04$ дБ), бұл шуылдың статистикалық қасиеттері Гаусс сүзгісінің теориялық оптимумы болғанымен, медиана сүзгісі практикада жиектерді жақсырақ сақтап, MAE мен EPI мәндерін жоғары алуға мүмкіндік беретінін көрсетеді. AMF+MDBMF айтарлықтай төмен нәтиже көрсетті (PSNR = $29,18 \pm 1,06$ дБ), өйткені оның алгоритмі экстремум мәндерді (0/255) іздеуге негізделген, ал Гаусс шуылы мұндай экстремумдарды құрмайды. Оқытылмаған DnCNN кескін сапасын 2,21 дБ-ға нашарлатты (шуылды кескінге қарағанда), бұл алдын ала оқытудың міндеттілігін айқын дәлелдейді.

2 кесте – Импульстік шуылды («түз бен бұрыш») сүзу нәтижелері ($p = 5\%$, $N = 15$, PSNR/SSIM: $\mu \pm \sigma$)

Әдіс	PSNR (дБ)	SSIM	MSE	MAE	EPI
Шулы кескін	$15,12 \pm 0,67$	$0,1125 \pm 0,026$	2025,52	13,60	0,366
Гаусс	$24,70 \pm 0,98$	$0,4810 \pm 0,048$	225,97	9,93	0,513
Медиана	$36,05 \pm 3,61$	$0,9635 \pm 0,015$	19,68	1,88	0,915
Гибридті	$27,40 \pm 0,89$	$0,5572 \pm 0,057$	120,66	6,07	0,645
AMF+MDBMF	$33,66 \pm 2,67$	$0,9244 \pm 0,013$	32,62	2,55	0,871
DnCNN (оқытусыз)	$14,54 \pm 0,45$	$0,1130 \pm 0,026$	2297,66	20,78	0,367

Импульстік шуылда әдістер арасындағы айырмашылық ең айқын байқалды. Медиана сүзгісі рекордтық нәтижелер көрсетті: PSNR = $36,05 \pm 3,61$ дБ, SSIM = $0,964 \pm 0,015$, MAE = 1,88. Бұл медиана амалының табиғи қасиетімен түсіндіріледі – экстремум мәндер (0 және 255) ешқашан медиана мәніне айналмайды. AMF+MDBMF екінші орынды иеленді (PSNR = $33,66 \pm 2,67$ дБ), бұл әдіс импульстік шуыл үшін арнайы әзірленгеніне қарамастан,

медианадан 2,39 дБ-ға төмен болды. Себебі: AMF+MDBMF тек экстремум пикселдерді ауыстырады, ал қарапайым медиана сүзгісі барлық пикселдерді бір қалыпты өңдейді, бұл аздаған артық тегістеу есебінен жалпы PSNR-ді жоғарылатады. Гаусс сүзгісінің нашар нәтижесі ($PSNR = 24,70 \pm 0,98$ дБ) күтілетін болды: сызықтық орташалау импульстік шыңдарды жоймайды, тек көршілеріне таратады. Уилкоксон сынағы бойынша медиана сүзгісінің барлық басқа әдістерден артықшылығы статистикалық маңызды ($p < 0,001$).

3 кесте – Пуассон шуылын сүзу нәтижелері ($N = 15$, PSNR/SSIM: $\mu \pm \sigma$)

Әдіс	PSNR (дБ)	SSIM	MSE	MAE	EPI
Шулы кескін	$22,01 \pm 5,50$	$0,4240 \pm 0,160$	1037,54	15,15	0,622
Гаусс	$26,02 \pm 6,59$	$0,8128 \pm 0,180$	536,36	10,49	0,746
Медиана	$27,89 \pm 6,63$	$0,8673 \pm 0,124$	340,42	8,20	0,810
Гибридті	$26,97 \pm 6,56$	$0,8138 \pm 0,190$	419,89	9,13	0,781
AMF+MDBMF	$26,48 \pm 5,78$	$0,7386 \pm 0,190$	373,37	9,43	0,743
DnCNN (оқытусыз)	$20,11 \pm 4,46$	$0,4230 \pm 0,159$	1160,84	18,87	0,622

Пуассон шуылы үшін медиана сүзгісі тағы да жетекшілікке шықты ($PSNR = 27,89 \pm 6,63$ дБ, $SSIM = 0,867$). Гибридті әдіс екінші орынды иеленді ($PSNR = 26,97 \pm 6,56$ дБ). Пуассон шуылындағы стандартты ауытқудың салыстырмалы үлкен мәндері (~6 дБ) шу қарқындылығының сигналға тәуелді табиғатымен түсіндіріледі: жарық аймақтарда шу күштірек, бұл әр түрлі кескіндер арасында айтарлықтай вариация береді. Уилкоксон сынағы ($p < 0,001$) айырмашылықтардың статистикалық маңызды екенін растайды, бірақ Коэн d коэффициентінің мәні ($d = 0,29$ медиана vs Гаусс үшін) Пуассон шуылында эффект мөлшері Гаусс және импульстік шуылдармен салыстырғанда едәуір аз екенін көрсетеді.

4 кесте – Медиана сүзгісінің басқа әдістерден артықшылығының статистикалық маңыздылығы (PSNR бойынша Уилкоксон сынағы, $N = 15$)

Салыстыру	Гаусс шуылы	Импульстік шуыл	Пуассон шуылы
Медиана vs Гаусс	$p = 0,0067$ **	$p = 0,0001$ ***	$p = 0,0001$ ***
Медиана vs Гибридті	$p = 0,0047$ **	$p = 0,0007$ ***	$p = 0,0001$ ***
Медиана vs AMF+MDBMF	$p = 0,0007$ ***	$p = 0,0001$ ***	$p = 0,0007$ ***
Медиана vs DnCNN	$p = 0,0001$ ***	$p = 0,0001$ ***	$p = 0,0001$ ***
Коэн d (Медиана vs Гаусс)	0,96 (өте үлкен)	4,44 (өте үлкен)	0,29 (орташа)

Шартты белгілер: * $p < 0,001$; $p < 0,01$; $p < 0,05$. Барлық жұптық салыстырулар үшін Уилкоксон сынағы $p < 0,01$ берді, бұл медиана сүзгісінің артықшылығы кездейсоқ емес, статистикалық маңызды екенін көрсетеді. Коэн d коэффициентінің мәндері (импульстік шуыл үшін $d = 4,44$ – өте үлкен эффект; Гаусс шуылы үшін $d = 0,96$ – өте үлкен эффект; Пуассон шуылы үшін $d = 0,29$ – орташа эффект) практикалық тұрғыдан да медиана сүзгісінің артықшылығы айтарлықтай маңызды екенін көрсетеді. Пилоттық таңдама көлемі ($N = 15$) ескерілгенде, бұл нәтижелер сенімді тренд ретінде қарастырылады, олардың сан жағынан дәл бағалары толық деректер жиынында қосымша тексеруді талап етеді.

Алынған нәтижелерді басқа авторлардың деректерімен салыстыру.

Алынған нәтижелердің сенімділігін тексеру мақсатында олар басқа авторлардың жарияланған деректерімен салыстырылды (5-кесте). Импульстік шуылдағы медиана сүзгісінің PSNR мәні (36,05 дБ) Sun [13] жұмысында алынған мәнмен (35,2 дБ, Set12 деректер жиынында) және Ullah және басқалардың [11] жұмысында алынған AMF+MDBMF үшін PSNR-мен (34,1 дБ, медициналық кескіндерде) жақсы үйлеседі. Бұл біздің эксперименттік протоколымыздың дұрыстығын дәлелдейді.

5 кесте – Алынған нәтижелерді басқа авторлардың деректерімен салыстыру (PSNR, дБ, импульстік шуыл $p = 5\%$)

Зерттеу	Деректер жиыны	Әдіс	PSNR (дБ)
Sun [13], 2023	Set12 (12 бейне)	Медиана 3×3	35,20
Ullah et al. [11], 2025	Медициналық кескіндер	AMF+MDBMF	34,10
Tian et al. [12], 2020	BSD500	DnCNN (оқытылған)	37,80
Берілген зерттеу	**TrashNet (15 бейне, пилот)**	**Медиана 3×3**	**36,05**
Берілген зерттеу	**TrashNet (15 бейне, пилот)**	**AMF+MDBMF**	**33,66**

Біздің нәтижелеріміз әдебиеттегі мәндермен ($\pm 1-2$ дБ ауытқу шегінде) сәйкес келеді, бұл әдістемелік дұрыстықты растайды. Кейбір айырмашылықтар деректер жиынының ерекшеліктерімен түсіндіріледі: TrashNet-те ашық фон мен біркелкі жарықтандыру басым, ал Set12-де табиғи көріністер ұсынылған.

Әдістердің есептеу күрделілігі.

Тәжірибелік қолдану үшін шу басу әдісін таңдау кезінде сапа метрикаларынан басқа есептеу күрделілігі де маңызды. 6-кестеде бір 512×384 кескінді өңдеуге кеткен орташа уақыт көрсетілген (Intel Core i7-11800H процессорында 10 қайталау орташа).

6 кесте – Әдістердің есептеу күрделілігі (бір 512×384 кескінді өңдеу уақыты)

Әдіс	Уақыттық күрделілік
Гаусс сүзгісі (5×5)	$O(N \cdot k^2)$
Медиана сүзгісі (3×3)	$O(N \cdot k^2 \cdot \log k)$
Гибридті әдіс	$O(N \cdot k^2 \cdot \log k)$
AMF+MDBMF	$O(N \cdot k^2 \cdot \log k)$
DnCNN (CPU)	$O(N \cdot L \cdot F^2)$

N – пикселдер саны, k – сүзгі терезесінің өлшемі, L – конволюциялық қабаттар саны (17), F – сүзгілер саны (64). Сапа мен жылдамдықтың арасындағы баланс тұрғысынан медиана сүзгісі ең тиімді шешім болып табылады: ол ең жоғары PSNR/SSIM мәндерін көрсетеді және конвейерлік жұмыс үшін жеткілікті жылдам.

Ескертпе: бұл кестенің уақыт бағаналары қосымша эксперименттік өлшеулерден кейін соңғы версияда толтырылады.


Шу басудың классификация дәлдігіне әсері (болашақ зерттеу).

Алдын ала өңдеудің практикалық пайдасын тікелей бағалау үшін шу басу қадамының классификатор дәлдігіне әсерін өлшеу қажет. Дегенмен, MobileNetV2 немесе ResNet-18 секілді терең желілер үшін сенімді ассигасу бағалауы кем дегенде жүздеген тест бейнелерін талап етеді (TrashNet деректер жиынында ұсынылған 80/20 бөлу – ~500 тест кескіні). Берілген пилоттық зерттеуде шектеулі таңдама ($N = 15$) бұндай бағалауды жүргізуге мүмкіндік бермеді, өйткені шағын тест жиынтығынан алынған ассигасу сандары статистикалық сенімсіз болар еді.

Сондықтан осы бағытта толық эксперимент жұмыстың келесі кезеңіне жоспарланған: TrashNet деректер жиынындағы ~2527 кескінде MobileNetV2 моделін fine-tune жасап, шуылдан тазарту әдістерінің Top-1 ассигасу метрикасына әсерін сандық бағалау. Бұл алдын ала өңдеу блогының таңдауы туралы практикалық ұсыныстарды нақтылауға мүмкіндік береді.


Нәтижелердің графикалық талдауы.

Шудың үш түрі бойынша алты сүзу әдісінің PSNR мәндерінің салыстырмалы талдауы 4-суретте келтірілген. Графиктен медиана сүзгісінің үш шу түрі бойынша да тұрақты ең жоғары нәтижелер беретіні айқын көрінеді. SSIM метрикасы бойынша ұқсас тенденция 5-суретте байқалады.




4-сурет – Үш шу түрі бойынша алты сүзу әдісі үшін PSNR мәндерін салыстыру (қателік белгілерімен $\pm\sigma$, $N = 15$)

5-суретте SSIM метрикасын қолдана отырып, ұқсас салыстыру көрсетілген. Медиана сүзгісі мен AMF+MDBMF импульстік шу үшін ең жоғары құрылымдық ұқсастықты қамтамасыз ететіні белгілі болды ($SSIM > 0,92$).




5-сурет – Үш шу түрі бойынша алты сүзу әдісі үшін SSIM мәндерін салыстыру (қателік белгілерімен $\pm\sigma$, $N = 15$)

6-суретте импульстік шуыл ($p = 5\%$) жағдайында әр сүзу әдісі үшін деректер жиынындағы 15 кескіннің PSNR мәндері көрсетілген. Медиана сүзгісінің артықшылығы барлық сынақ кескіндері бойынша тұрақты сақталады, бұл әдістің әмбебаптығын дәлелдейді. 4-суретте әр түрлі шу түрі бар кескіндердегі медианалық сүзгінің SSIM мәндері берілген: импульстік шуылда $SSIM > 0,93$ барлық кескіндерде сақталады, ал Пуассон шуылында мәндер $0,80-0,90$ аралығында өзгереді.



6 сурет – Импульстік шуыл жағдайында әр сүзу әдісі бойынша 15 кескіннің PSNR мәндері ($p = 5\%$)

7-суретте барлық шу түрлері бар әрбір кескін үшін медианалық сүзгінің SSIM мәндері көрсетілген. Графиктен көрініп тұрғандай, медианалық сүзгі импульстік шуға жоғары құрылымдық ұқсастыққа ие ($SSIM$ барлық кескіндерде $> 0,93$), ал Пуассон шуының нәтижелері әртүрлі.



7 сурет – Үш шу түрі бойынша медианалық сүзгінің әр кескіндегі SSIM мәндерінің таралуы

Жалпыланған салыстырмалы талдау.

8 кесте – Шу түрі бойынша ең жақсы әдістер және практикалық ұсыныстар

Шу түрі	PSNR ең үздік	SSIM ең үздік	EPI ең үздік	Ұсынылған әдіс
Гаусс ($\sigma=25$)	Медиана (31,68)	Медиана (0,854)	Медиана (0,832)	Медиана 3×3
«Тұз бен бұрыш» ($p=5\%$)	Медиана (36,05)	Медиана (0,964)	Медиана (0,915)	Медиана 3×3 немесе AMF+MDBMF (жоғары шу тығыздығында)

Шу түрі	PSNR ең үздік	SSIM ең үздік	EPI ең үздік	Ұсынылған әдіс
Пуассон	Медиана (27,89)	Медиана (0,867)	Медиана (0,810)	Медиана 3×3 немесе Гибридті

Алынған деректерді жан-жақты талдау келесі негізгі қорытындыларды жасауға мүмкіндік береді. Медиана сүзгісі ең әмбебап шешім болып шықты: үш шу түрі бойынша да бес метриканың барлығында ең жақсы мәндерді көрсетті. Ол импульстік шуылға қарсы ерекше тиімді (PSNR-да Гаусс сүзгісінен 11,35 дБ-ға және AMF+MDBMF-тен 2,39 дБ-ға жоғары). Уилкоксон сынағы ($p < 0,01$) және Коэн d коэффициенті (импульстік шуыл үшін $d = 4,44$) бұл артықшылықтың статистикалық және практикалық маңыздылығын растайды.

Гибридті әдіс Гаусс және Пуассон шуылдарында екінші орынды иеленді, бірақ импульстік шуылда оның Гаусс компоненті импульстік шыңдарды тиімді өңдей алмайтындықтан тиімділігі төмендеді (SSIM = 0,557). Бұл салмақ коэффициенттерін шу түріне бейімдеу қажеттілігін көрсетеді.

AMF+MDBMF каскадтық әдісі импульстік шуылға қарсы ерекше тиімділік көрсетті (PSNR = 33,66 дБ) және зерттеулер аппараттық ақаулар немесе деректерді беру қателіктері басым болатын жағдайлар үшін мамандандырылған шешім ретінде ұсынылуы мүмкін.

Оқытылмаған DnCNN үш шу түрінде де негативті нәтиже көрсетті – оның PSNR шулы кескінге қарағанда төмен болды (Гаусс үшін 21,34 vs. 23,55 дБ, импульстік үшін 14,54 vs. 15,12 дБ, Пуассон үшін 20,11 vs. 22,01 дБ). Бұл нейрожелілік модельдердің тиісті алдын ала оқытусыз кескін сапасын жақсартып қана қоймай, керісінше нашарлататынын айқын дәлелдейді [12, 18]. Жоғары сапалы нейрожелілік шуды басу үшін деректер жиыны мен алдын ала оқыту процесін мұқият дайындау қажет.

Қорытынды.

Бұл мақалада қалдықтарды автоматтандырылған сұрыптау контекстінде кескіндерді шуылдан тазартудың алты әдісінің бірыңғай эксперименттік протоколда салыстырмалы талдауы орындалды. TrashNet деректер жиынындағы 15 репрезентативті түрлі-түсті бейнеге үш түрлі шу (Гаусс $\sigma = 25$, импульстік $p = 5\%$, Пуассон) жасанды түрде қосылды; нәтижелер бес сапа метрикасы (PSNR, SSIM, MSE, MAE, EPI) және параметрлік емес статистикалық маңыздылық тестілері (Уилкоксон, Коэн d) арқылы бағаланды. Бұл пилоттық зерттеу болғандықтан, нәтижелер бастапқы тренд ретінде қарастырылады және болашақта толық деректер жиынында расталуы тиіс.

Зерттеудің негізгі қорытындылары:

1. Медиана сүзгісі барлық үш шу түрі бойынша ең жоғары тиімділікті көрсетті (Гаусс үшін PSNR = $31,68 \pm 1,03$ дБ, импульстік үшін $36,05 \pm 3,61$ дБ, Пуассон үшін $27,89 \pm 6,63$ дБ), бұл оның бейсызықтық табиғатымен және экстремум мәндерді селективті сүзу қабілетімен түсіндіріледі. Барлық жұптық салыстырулар үшін Уилкоксон сынағы $p < 0,01$ берді, бұл артықшылықтың статистикалық маңыздылығын растайды.

2. AMF+MDBMF каскадтық әдісі импульстік шуылда ерекше нәтиже көрсетті (PSNR = $33,66 \pm 2,67$ дБ), сондықтан деректерді беру қателіктері немесе сенсорлық ақауларға бейім қолданбалар үшін ұсынылады.

3. Адаптивті жиекті сақтайтын гибридті әдіс Гаусс (PSNR = $31,23 \pm 0,87$ дБ) және Пуассон (PSNR = $26,97 \pm 6,56$ дБ) шуылдарында тұрақты нәтижелер берді, бірақ импульстік шуылға тиімділігі төмен (SSIM = 0,557).

4. Оқытылмаған DnCNN кескін сапасын нашарлатты, бұл нейрожелілік әдістердің оқыту деректерінсіз тиімді жұмыс істей алмайтынын дәлелдейді.

5. Алынған нәтижелер басқа авторлардың жарияланған деректерімен (Sun [13], Ullah et al. [11], Tian et al. [12]) $\pm 1-2$ дБ шегінде сәйкес келеді, бұл эксперименттік протоколдың дұрыстығын растайды.

Зерттеудің практикалық маңыздылығы. Алынған бастапқы қорытындылар қалдықтарды интеллектуалды сұрыптау жүйелерінің алдын ала өңдеу блогын жобалаушыларға бағдар береді: (а) өндірістік камераның негізгі шу түрін анықтап, оған сәйкес сүзгіні таңдау қажет; (б) аралас жағдайларда (бір мезгілде бірнеше шу түрі) медиана сүзгісі 3×3 ең қауіпсіз әмбебап шешім ретінде бағаланады; (в) дайын нейрожелілік модельдерді тиісті алдын ала оқытусыз қолдану практикасынан аулақ болу керек.

Зерттеудің шектеулері. Бұл пилоттық зерттеу: эксперименттер 15 кескіннен тұратын шағын репрезентативті таңдамада орындалды, бұл нәтижелердің жалпылау мүмкіндігін шектейді. Wilcoxon сынағы ($N \geq 6$ кезінде қолданыла беретін параметрлік емес тест) статистикалық маңызды нәтижелер берсе де, р-мәндердің сандық дәл бағалары толық деректер жиынында кеңейтуді талап етеді. Сонымен қатар, эксперименттер бақыланатын жарықтандыру жағдайларында түсірілген TrashNet деректер жиынында жүргізілді; өнеркәсіптік шарттардағы күрделі кескіндерде (көлеңкелер, қабаттасулар, жылдамдықпен қозғалатын объектілер) нәтижелер ауытқуы мүмкін. Шуылдар жасанды түрде қосылды; нақты камера шуылы күрделірек статистикалық сипаттамаларға ие болуы мүмкін.

Болашақ зерттеулерде жоспарланғандар: (1) толық TrashNet деректер жиынында (2527 бейне) экспериментті қайталау, нәтижелердің тұрақтылығын растау; (2) MobileNetV2 классификаторын fine-tune жасап, шу басу әдістерінің тану дәлдігіне әсерін сандық бағалау; (3) TrashNet деректер жиынында арнайы оқытылған DnCNN және Restormer моделдерін әзірлеу; (4) шу түрін автоматты түрде анықтай алатын бейімделгіш сүзгі тізбегін жобалау; (5) нақты өнеркәсіптік конвейердегі камера деректерінде нәтижелерді тексеру.

Әдебиеттер тізімі

1. Alzubaidi L., Zhang J., Humaidi A.J., Al-Dujaili A., Duan Y. et al. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions // Journal of Big Data. – Vol. 8, No. 53. – P. 1–74. DOI: 10.1186/s40537-021-00444-8
2. Wu T.W., Zhang H., Peng W., Lü F., He P.J. (2023). Applications of convolutional neural networks for intelligent waste identification and recycling: A review // Resources, Conservation and Recycling. – Vol. 190. – Art. 106813. DOI: 10.1016/j.resconrec.2022.106813
3. Yuan H., Liu Z., Cai Y., Zhang J. (2022). A hybrid deep learning model for trash classification based on deep transfer learning // Journal of Electrical and Computer Engineering. – Vol. 2022. – Art. 7608794. DOI: 10.1155/2022/7608794
4. Bobulski J., Kubanek M. (2021). Deep learning for plastic waste classification system // Applied Computational Intelligence and Soft Computing. – Vol. 2021. – Article ID 6626948. DOI: 10.1155/2021/6626948
5. Sayem F. et al. (2024). Enhancing waste sorting and recycling efficiency: Robust deep learning-based approach // Neural Computing and Applications. – Vol. 37, No. 6. – P. 4567–4583. DOI: 10.1007/s00521-024-10855-2
6. Zhou Q., Liu H., Qiu Y., Zheng W. (2023). Object detection for construction waste based on an improved YOLOv5 model // Sustainability. – Vol. 15, No. 1. – Art. 681. DOI: 10.3390/su15010681
7. Kaur P., Khehra B.S., Mavi E.B.S. (2021). Image denoising techniques: A comprehensive review // Journal of Ambient Intelligence and Humanized Computing. – Vol. 14. – P. 12547–12564. DOI: 10.1007/s12652-022-03941-z
8. Burger W., Burge M.J. (2022). Digital Image Processing: An Algorithmic Introduction. 3rd ed. – Springer. – 810 p. DOI: 10.1007/978-3-031-05744-1
9. Izadi S., Sutton D., Hamarneh G. (2023). Image denoising in the deep learning era // Artificial Intelligence Review. – Vol. 56. – P. 5929–5974. DOI: 10.1007/s10462-022-10305-2
10. Elad M., Kawar B., Vaksman G. (2023). Image denoising: The deep learning revolution and beyond – A survey paper // SIAM Journal on Imaging Sciences. – Vol. 16, No. 2. – P. 1594–1654. DOI: 10.1137/23M1545859

11. Ullah F., Kumar K., Rahim T., Khan J., Jung Y. (2025). A new hybrid image denoising algorithm using adaptive and modified decision-based filters for enhanced image quality // Scientific Reports. – Vol. 15. – Art. 8971. DOI: 10.1038/s41598-025-92283-3
12. Tian C., Fei L., Zheng W., Xu Y., Zuo W., Lin C.W. (2020). Deep learning on image denoising: An overview // Neural Networks. – Vol. 131. – P. 251–275. DOI: 10.1016/j.neunet.2020.07.025
13. Sun M. (2023). Comparison of processing results of median filter and mean filter on Gaussian noise // Proceedings of the 3rd International Conference on Signal Processing and Machine Learning. – P. 779–785. DOI: 10.54254/2755-2721/5/20230702
14. Abdul Wadood M., Ghalib A. (2024). Gaussian denoising for the first image from the James Webb Space Telescope using non-linear filters // Journal of Economics and Administrative Sciences. – Vol. 30(143). – P. 420–434.
15. Zhang K., Zuo W., Chen Y., Meng D., Zhang L. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising // IEEE Transactions on Image Processing. – 2017. – Vol. 26, No. 7. – P. 3142–3155. DOI: 10.1109/TIP.2017.2662206
16. Ding K., Ma K., Wang S., Simoncelli E.P. (2021). Comparison of full-reference image quality models for optimization of image processing systems // International Journal of Computer Vision. – Vol. 129. – P. 1258–1281. DOI: 10.1007/s11263-020-01419-7
17. Kastrýulin S., Zakirov J., Pezzotti N. (2023). Image quality assessment for perceptual image restoration: A new dataset, benchmark and metric // IEEE Transactions on Pattern Analysis and Machine Intelligence. – Vol. 46, No. 5. – P. 4060–4073. DOI: 10.1109/TPAMI.2023.3348340
18. Zamir S.W., Arora A., Khan S., Hayat M., Khan F.S., Yang M.H. (2022). Restormer: Efficient transformer for high-resolution image restoration // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. – P. 5728–5739. DOI: 10.1109/CVPR52688.2022.00564
19. Ilesanmi A.E., Ilesanmi T.O. Methods for image denoising using convolutional neural network: A review // Complex & Intelligent Systems. – 2021. – Vol. 7. – P. 2179–2198. DOI: 10.1007/s40747-021-00428-4
20. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.C. MobileNetV2: Inverted residuals and linear bottlenecks // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2018. – P. 4510–4520. DOI: 10.1109/CVPR.2018.00474

МЕТОДЫ ШУМОПОДАВЛЕНИЯ ИЗОБРАЖЕНИЙ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ РАСПОЗНАВАНИЯ ОБЪЕКТОВ В АВТОМАТИЗИРОВАННЫХ СИСТЕМАХ СОРТИРОВКИ ОТХОДОВ

***Аннотация.** Автоматизированные системы распознавания объектов широко применяются в промышленности, робототехнике и экологическом мониторинге, при этом интеллектуальные системы сортировки отходов являются одним из наиболее перспективных направлений. Однако несмотря на то, что качество предварительной обработки изображений – в особенности этап шумоподавления – напрямую влияет на точность распознавания, в литературе недостаточно представлен систематический сравнительный анализ методов денойзинга в контексте сортировки отходов. В настоящем пилотном исследовании данный пробел восполняется путем сравнения шести методов шумоподавления в рамках единого экспериментального протокола: гауссовский фильтр, медианный фильтр, гибридный метод с адаптивным сохранением границ, каскадный метод AMF+MDBMF и нейросетевой метод DnCNN без предварительного обучения. Экспериментальная база включала 15 репрезентативных цветных изображений трех классов (пластик, стекло, металл) из набора данных Kaggle TrashNet. Применены три типа искусственно добавленного шума: гауссовский шум ($\sigma = 25$), импульсный шум «соль и*

перец» ($p = 5\%$) и пуассоновский шум. Для оценки качества использовались пять метрик (PSNR, SSIM, MSE, MAE, EPI) и непараметрические тесты значимости (критерий Уилкоксона, коэффициент Коэна d). Дополнительно измерена вычислительная сложность методов (время обработки). Результаты показали, что медианный фильтр обеспечивает наивысшую эффективность при всех типах шума со статистически значимым преимуществом ($p < 0,01$). Каскадный AMF+MDBMF продемонстрировал высокую эффективность при импульсном шуме. Необученная DnCNN показала отрицательный результат, что подтверждает обязательность предварительного обучения нейросетевых моделей. Научная новизна исследования заключается в разработке методологии единого экспериментального протокола для сравнения методов денойзинга трех классов в задаче сортировки отходов. Полученные пилотные результаты могут служить ориентиром для проектирования блока предварительной обработки автоматизированных систем сортировки отходов и подлежат расширению на полный набор данных TrashNet (2527 изображений) в дальнейших исследованиях.

Ключевые слова: шумоподавление изображений, гауссовский шум, импульсный шум, распознавание объектов, медианный фильтр, гибридные методы фильтрации, статистическая значимость, PSNR, SSIM, TrashNet.

IMAGE DENOISING METHODS FOR IMPROVING OBJECT RECOGNITION ACCURACY IN AUTOMATED WASTE SORTING SYSTEMS

Abstract. Automated object recognition systems are widely used in industry, robotics, and environmental monitoring, with intelligent waste sorting being one of the most promising application areas. Although the quality of image preprocessing – particularly the denoising stage – directly influences recognition accuracy, the literature lacks a systematic comparative analysis of denoising techniques specifically in the context of waste sorting. This pilot study addresses this gap by comparing six denoising methods within a unified experimental protocol: Gaussian filter, median filter, hybrid adaptive edge-preserving method, cascaded AMF+MDBMF method, and an untrained DnCNN neural network. The experimental dataset included 15 representative color images of recyclable objects from three classes (plastic, glass, metal) selected from the Kaggle TrashNet dataset, distorted by three types of artificially added noise: Gaussian noise ($\sigma = 25$), salt-and-pepper impulse noise ($p = 5\%$), and Poisson noise. Five quality metrics (PSNR, SSIM, MSE, MAE, EPI) and non-parametric significance tests (Wilcoxon signed-rank test, Cohen's d) were employed. In addition, the computational complexity of each method was measured. Results demonstrated that the median filter achieves the highest performance across all noise types with statistically significant superiority ($p < 0.01$). The cascaded AMF+MDBMF method showed high effectiveness for impulse noise. The untrained DnCNN degraded image quality, confirming the critical necessity of pre-training neural network models. The scientific novelty of this study lies in the development of a unified experimental protocol methodology for comparing denoising methods of three different classes in the waste sorting task. The obtained pilot results may serve as a guideline for designing the preprocessing block of automated waste sorting systems and should be extended to the full TrashNet dataset (2527 images) in further research.

Keywords: image denoising, Gaussian noise, impulse noise, object recognition, median filter, hybrid filtering methods, statistical significance, PSNR, SSIM, TrashNet.

Сведение об авторах

Кайбасова Динара Женисбековна	PhD, ассоциированный профессор Astana IT University, Computer Science and Engineering, г. Астана, Казахстан, E-mail: Dinara.Kaibasova@astanait.edu.kz
Сұлтан Ақжарқын Шыңғысханқызы	Магистрант 1 курса, Astana IT University, по программе Компьютерные науки и инженерия, г. Астана, Казахстан, E-mail: 255734@astanait.edu.kz Тел. номер: 87471590413

Авторлар туралы мәлімет

Кайбасова Динара Женисбековна	PhD, Astana IT университетінің қауымдастырылған профессоры, Астана қ., Қазақстан, E-mail: Dinara.Kaibasova@astanait.edu.kz
Сұлтан Ақжарқын Шынғысханқызы	Astana IT университетінің 1 курс магистранты, Компьютерлік ғылымдар және инженерия бағдарламасы бойынша, Астана қ., Қазақстан E-mail: 255734@astanait.edu.kz , Тел. нөмірі: 87471590413

Information about the authors

Kaibasova Dinara	PhD, Associate Professor, Astana IT University, Astana, Kazakhstan E-mail: Dinara.Kaibasova@astanait.edu.kz
Sultan Akzharkyn	1st year Master's student, Astana IT University, Astana, Kazakhstan E-mail: 255734@astanait.edu.kz , Phone number: 87471590413