

=====

КОМПЬЮТЕРЛІК ҒЫЛЫМДАР, АСПАП ЖАСАУ ЖӘНЕ АВТОМАТТАНДЫРУ
КОМПЬЮТЕРНЫЕ НАУКИ, ПРИБОРОСТРОЕНИЯ И АВТОМАТИЗАЦИЯ
COMPUTER SCIENCE, INSTRUMENTATION AND AUTOMATION

=====

ӘОЖ 004.85

ҒТАХА 28.23.25

https://doi.org/10.53364/24138614_2025_36_1_7

Н. Алимбекова^{1,2}, Х.М. Рай³, Т. Турымбетов⁴, А. Жумадилаева^{1*}

¹Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан

²Астана Халықаралық университеті, Астана, Қазақстан

³Жахон университеті, Соннам-си, Оңтүстік Корея

⁴Халықаралық Туризм және Меймандостық Университеті, Түркістан, Қазақстан

E-mail: ay8222@mail.ru*

ПОЛИМЕРЛІ КОНТЕЙНЕРЛЕРДІ СҰРЫПТАУ ПРОЦЕСІН
ОҢТАЙЛАНДЫРУ ҮШІН НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ҚОЛДАНУ

***Аңдатпа.** Бұл зерттеуде пластикалық контейнерлерді тиімді сұрыптау үшін конволюционды нейрондық желілерді (CNN) және ұзақ қысқа мерзімді жады (LSTM) біріктіретін гибриді нейрондық желі архитектурасын пайдалануды қарастырады. Зерттеу жақын инфрақызыл (NIR) спектроскопиялық құрылғысымен алынған, химиялық құрамы мен ластану деңгейіне байланысты пластикалық қалдықтарды жіктеуге бағытталған. Эксперимент нәтижелері CNN+LSTM гибриді моделі пластиктердің әртүрлі түрлері мен түстерін тану, соның ішінде контейнерлердегі ластанушы заттарды анықтауда салыстырмалы түрде жоғары дәлдікке қол жеткізетінін көрсетеді. Модельдің өнімділігін салыстырмалы бағалау логистикалық регрессия, ішінара ең кіші квадраттар (PLS) және сызықтық дискриминантты талдау (LDA) сияқты дәстүрлі жіктеу әдістерімен жүргізілді. Нәтижелер CNN+LSTM үлгісі дәстүрлі тәсілдерге қарағанда, әсіресе класстар арасындағы спектрлік айырмашылықтары аз сценарийлерде тиімдірек жұмыс істейтінін көрсетеді. Бұл зерттеу пластикалық қалдықтарды сұрыптау және қайта өңдеу процестерінің тиімділігін арттыру үшін машиналық оқытудың әлеуетін көрсетеді, осылайша экологиялық тұрақтылықты жақсартуға ықпал етеді.*

***Түйін сөздер:** Пластикалық қалдықтар, NIRS, Нейрондық желі, Гибриді модель, CNN, LSTM.*

Кіріспе.

Дүниежүзілік пластикалық қаптама нарығының көлемі 2024 жылы 103,48 миллион тоннаға бағаланады және 2029 жылға қарай 123,26 миллион тоннаға жетеді деп күтілуде, бұл ретте болжамды кезең ішінде (2024-2029 жылдар) орташа жылдық өсу қарқыны 3,56% құрайды. Пластикалық полимер қаптамаға сұраныс тұрақты өсуде, өйткені ол жеңіл және қолдануға ыңғайлы. Пластик өндіріс шығындарының төмендігіне байланысты тұтынушылар мен өндірушілер үшін де қолайлы. Полимерлі контейнерлердің сусындар, тамақ, косметика және фармацевтика салаларында маңыздылығы артып келеді (Mordor Intelligence, 2024).

Пластикалық қаптама өндірісі көлемінің артуы пластикалық қалдықтардың өсуіне әкеліп, оларды қайта өңдеудің әдістерін дамыту қажеттілігін арттырады, бұл қоршаған ортаға теріс әсерді болдырмау үшін маңызды. Полимер пластиктерді қайта өңдеу қоршаған ортаға теріс әсерді азайтудың маңызды шешімі ретінде қарастырамыз, алайда қолданыстағы қайта өңдеу инфрақұрылымы пластиктерді сұрыптау және жіктеуде бірқатар қиындықтарға тап болады. Пластиктердің қайта өңдеу барысында дұрыс жіктелмеуі немесе олардың ластануы екінші реттік материалдың сапасы мен қайта қолдану мүмкіндігін едәуір төмендетіп, экологиялық мәселелерді одан әрі күшейтеді.

Қайта өңдеу процестері ең алдымен пластиктің әртүрлі түрлерін ажырату үшін сенсорлар мен химиялық және физикалық қасиеттерді талдау сияқты озық әдістерді қолданады (Bonifazi және т.б., 2018). Дәстүрлі әдістер мысалы ретінде батыру-қалқымалы бөлу, шөктіру, гидроциклондау (Gent және т.б., 2018), электростатикалық бөлу және магниттік тығыздықты бөлу (Zhang және т.б., 2023) сияқты сұрыптау үшін полимерлердің физикалық қасиеттеріне сүйенеді. Дегенмен, бұл тәсілдер аралас пластиктерді немесе тығыздығы ұқсас пластмассаларды дәл сұрыптамауы мүмкін (Ragaert және т.б., 2017; Gundupalli және т.б., 2017). Мәселенің шешімі ретінде сенсорлық әдістер алдыңғы әдістерге қарағанда пластиктердің дәлірек және тиімді жіктелуін ұсынады.

Лазерлік индукцияланған ыдырау спектроскопиясы (LIBS), рентгендік сұрыптау және RGB камерасын қолдану арқылы сұрыптау сияқты әдістер кең таралған, бірақ олардың әрқайсысының шектеулері бар. LIBS әдісі пластикті анықтау кезінде сезімталдығының төмендігіне байланысты қиындықтарға тап болады (Shameem және т.б., 2017), рентген арқылы сұрыптау материалдарды ажыратуда шектеулі (Brunner және т.б., 2015), ал RGB камерасымен сұрыптау полимер пигменттерінің ұқсастығына және жарықтандыру мен ластану әсеріне ұшырауына байланысты нақты дәлдік қамтамасыз етпейді (Safavi және т.б., 2010).

Жақын инфрақызыл (NIR) спектроскопия және гиперспектральды бейнелеу жүйелерін пайдалана отырып, пластикалық қалдықтарды әртүрлі санаттарға жіктеуді автоматтандыру мақсатындағы көптеген зерттеулер бар (Qiu және т.б., 2020; Kumar және т.б., 2021; Tap және т.б., 2021; Ahmed және т.б., 2023; Singh және т.б., 2023). NIR спектроскопия арқылы бірегей спектрлік сипаттамаларына байланысты әртүрлі материалдарды, соның ішінде пластикті анықтауға арналған құрал ретінде бірқатар зерттеулер дәлелдеді (Masoumi және т.б., 2012; Marchesi және т.б., 2023). Белгілі бір толқын ұзындықтарында жарықтың жұтылуы, шағылысу және өткізгіштік қасиеттерін өлшеу арқылы NIR спектроскопиясы материалдың молекулалық құрамын анықтай алады, бұл пластик түрлерін ажыратуға мүмкіндік береді. Дегенмен, пластикалық қалдықтардың нақты деректерге негізделген жіктелуі ластаушы заттардың болуына және нақты өмірлік жағдайларда пластикалық қалдықтардың әртүрлі жағдайларына байланысты қиын болып қала береді.

Осы қиындықтарға жауап ретінде бұл зерттеуде пластикалық полимерлі контейнерлерді жіктеудің сенімді жүйесін әзірлеу үшін NIR-спектроскопиясымен алынған мәліметтермен нейрондық желілерді қолдану арқылы интеграциялау ұсынылады. Машиналық оқыту алгоритмдерінің жиынтығы болып табылатын нейрондық желілер үлкен және күрделі деректер жиынтығымен жұмыс істеуге өте ыңғайлы және кескінді тану, табиғи тілді өңдеу және соңғы уақытта материалдарды жіктеу мәселелерінде айтарлықтай жетістіктерге қол жеткізді (Xia және т.б., 2021; Olowolayemo және т.б., 2022).

Алдыңғы зерттеулердің басты мақсаты осы технологияларды қолдана отырып, жалпы қалдықтар ағынынан пластикті сұрыптау немесе оны полимер түріне қарай жіктеу болды. Алайда, бұл жұмыста пластик түрлерін тек материалдың түрі бойынша ғана емес, сонымен қатар түсі мен ластану деңгейіне қарай анықтау қарастырылады. Мысалы, бұл химиялық өнімдерге (шампуньдар мен тазартқыштар сияқты) пайдаланылған бөтелкелерді және қайта

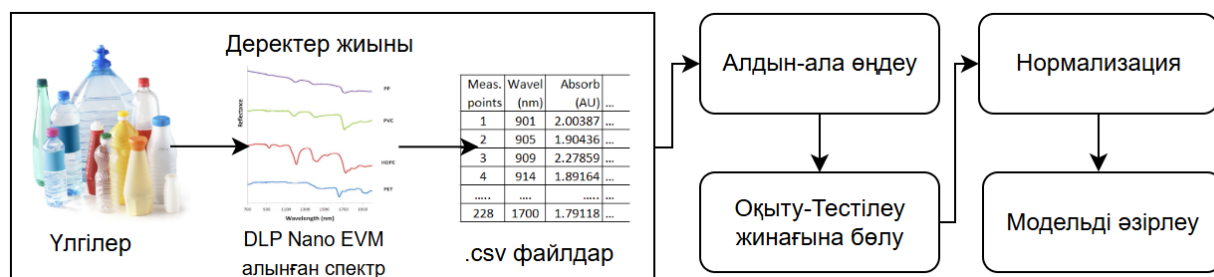
өңдеуге жатпайтын сүт өнімдеріне арналған контейнерлерді ажыратуды қамтиды. Мұндай қалдықтарды қайта өңдеу мүмкіндігі болғанымен, олардың көлемі әдетте аз, ал қайта өңдеу шығындары өте жоғары, сондықтан таза ПЭТ бөтелкелерін жинау және қайта өңдеу артықшылыққа ие болады.

Нейрондық желі моделін NIR спектрометрімен алынған сандық деректеріне үйрете отырып, бұл зерттеу ластану жағдайында да пластиктің жіктелу дәлдігін арттыруға тырысады, бұл сайып келгенде тиімдірек қайта өңдеу процестеріне және пластиктің ластану деңгейін төмендетуге ықпал етеді.

Материалдар мен әдістер.

Бұл зерттеу жақын инфрақызыл (NIR) спектроскопиясы мен машиналық оқытуды қолдана отырып, пластикалық қалдықтарды жіктеуге бағытталған деректерді жинау, өңдеу және талдау әдістерін сипаттайды.

Зерттеу бірнеше кезеңдерді қамтиды: спектрлік деректерді жинау және талдау, қалыпқа келтіру, оқыту және сынақ жиынтықтарына бөлуді қоса алғанда, деректерді алдын ала өңдеу, пластикалық контейнерлерді жіктеуге арналған моделді әзірлеу және оқыту (сурет-1).



1 сурет – Әзірленген әдістің жалпы көрінісі

Үлгілерді жинақтау.

Зерттеуге арналған мәліметтер жиынтығы үш кезеңге бөлінген, пластикалық бөтелкелерді материал түріне, мөлдірлігіне және ластану деңгейіне қарай жіктейді, деректердің 80% оқыту үшін және 20% сынақ үшін пайдаланылды.

Үлгілер DLP NIRScan Nano EVM (Texas Instruments, АҚШ), 900-ден 1700 нм-ге дейінгі 228 диапазондағы инфрақызыл спектрлерді анықтауға қабілетті жоғары интеграцияланған ультра портативті инфрақызыл спектрометрімен алынды. Төмендегі суретте үлгілерді түсіру барысы, бұл құрылғымен алынған спектрлар ашық немесе жабық кеңістікте айтарлықтай өзгеріс болмағанын көрсетті. Дегенмен бүкіл үлгілер жабық, қараңғы кеңістікте алынды.



а) DLP NIRScan Nano EVM портативті құрылғысы



б) үлгіні ашық кеңістікте түсіру



в) үлгіні жабық кеңістікте түсіру


2 сурет – Үлгілерді түсіру барысы

Бірінші кезеңде әр түрлі маркалы, таза-лас, 430 PET (полиэтилентерефталат) бөтелкелері мен контейнерлері, сондай-ақ тұрмыстық химиялық контейнерлерден PP (полипропилен), HDPE (тығыздығы жоғары полиэтилен) және LDPE (тығыздығы төмен полиэтилен) сияқты басқа пластиктердің 204 түрі бойынша жіктеу. Екінші кезеңде пластикалық контейнерлердің түсі бойынша жіктеледі, яғни 236 мөлдір бөтелке (таза немесе ластанған PET, PP болуы мүмкін) және 48 әртүлі түсті бөтелкелер (қанық немесе жартылай мөлдір болуы мүмкін). Үшінші кезең әртүрлі брендтердің 174 таза, бос PET бөтелкелері мен 209 сүт, май, соустар және зиянды сұйықтықтар сияқты өнімдерді сақтау үшін пайдаланылатын PET ластанған бөтелкелерді ажыратады. Бұл құрылымдық дерекқор пластикалық бөтелкелердің материал сапасы мен олардың ластану деңгейін егжей-тегжейлі зерттеуге мүмкіндік береді, бұл тиімді қайта өңдеу процестері үшін маңызды (Кесте-1).


1 кесте – Класстар бойынша құрылған үлгілер саны

Кезең	Класс	Саны
Кезең 1	ПЭТ	430
	Басқа (PP, LDPE, HDPE)	204
Кезең 2	Мөлдір	236
	Түрлі түсті (қанық)	48
Кезең 3	Таза	174
	Ластанған	209

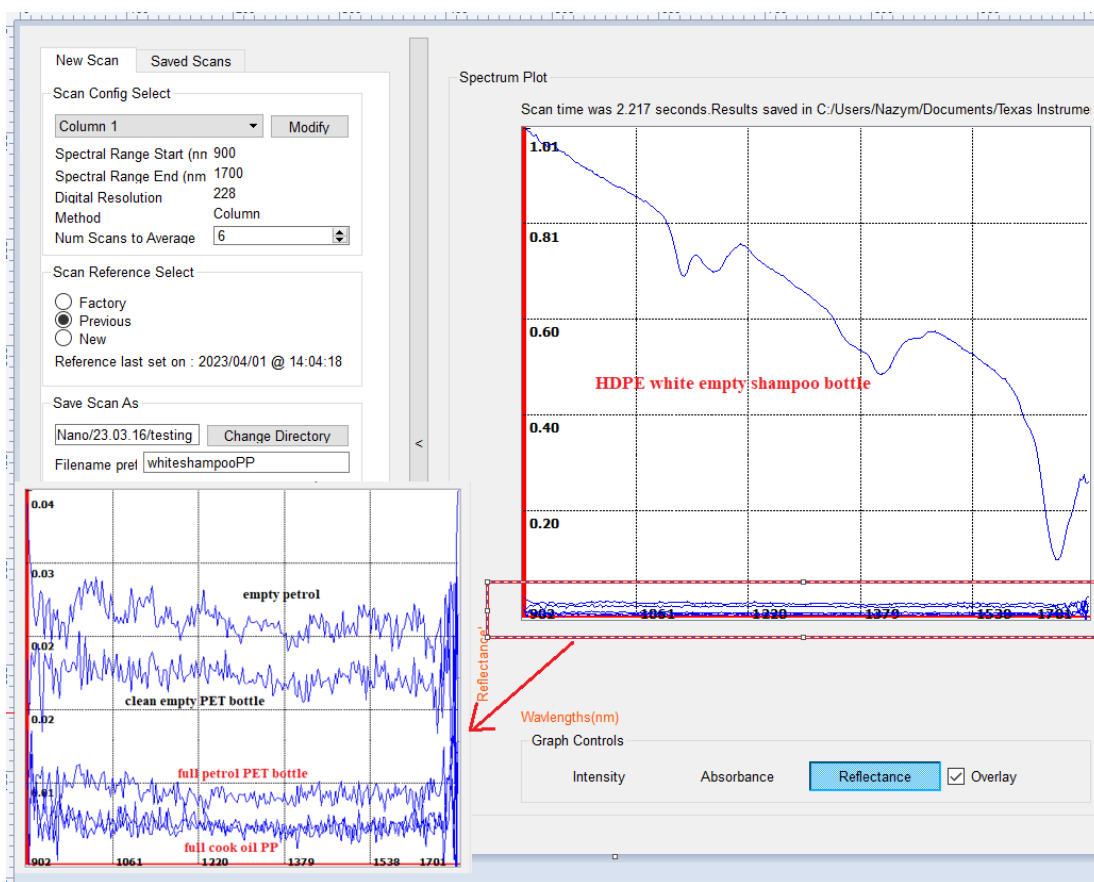
IRscanNano GUI v1.1.9 интерфейсі арқылы бейнеленген өңделмеген (raw data) үлгілердің шағылысу коэффициенті бойынша визуалды көрінісі. (сурет 3-5)



3 сурет – 1 кезең пластикалық бөтелкелерді типі бойынша салыстыру (Masoumi, H., т.б автордың мақаласынан алынды [16])



4 сурет – 2 кезең пластикалық бөтелкелерді түстері бойынша ажырату



5 сурет – 3 кезең пластикалық бөтелкелерді ластану деңгейі бойынша ажырату

Үлгілерді алдын-ала өңдеу кезеңінде, нейрондық желі олардың NIR спектрлік қолтаңбалары негізінде пластиктердің әртүрлі түрлерін ажыратуды тиімді үйренуін

қамтамасыз ету үшін спектрлік деректерді ұйымдастыруды және таңбалауды қамтиды. Қарастырылып отырған деректер жиыны спектрометрден 634 көрсеткішін қамтиды, әрбір көрсеткіш төрт баған бойынша спектрлік деректердің 228 жолын қамтиды: толқын ұзындығы (нм), абсорбция (AU), анықтамалық сигнал (бірліксіз) және үлгі сигналы (бірліксіз).

Алдын ала өңдеудің бастапқы қадамы екілік жіктеудің үш кезеңнің әрқайсысы үшін бүкіл деректер жиынтығын қайталауды қамтиды: ПЭТ-ті басқа пластик түрлерінен ажырату, мөлдір пластиктерді түрлі-түстіден ажырату және ПЭТ ластанған материалдардан таза ПЭТ анықтау. Қайталау (duplication) маңызды, өйткені әрбір тапсырма деректерге ерекше көзқарасты талап етеді, яғни сол классификация міндетіне қатысты нақты атрибуттарға назар аударады. Бұл кезең нейрондық желіні оқыту үшін өте маңызды, өйткені ол әр топтың сипаттамаларын білу үшін қажетті таңбаланған деректерді береді.

Таңбалаудан кейін деректер жиындары талдауға қажетті бірегей идентификаторлар мен белгілерді қамтитын бір CSV файлына біріктіріледі. Осы біріктірілген деректер жиынындағы бағандарға мыналар кіреді: Толқын ұзындығы (нм), Абсорбция (AU), Анықтамалық сигнал (бірліксіз), Үлгі сигналы (бірліксіз), Вариация, Үлгі_саны, Санат және Сенсор_идентификаторы. Мұндағы "Вариация" үш екілік жіктеу кезеңнің қайсысына жататынын көрсетеді, "Үлгі_саны" әрбір спектрлік көрсеткіш үшін бірегей идентификатор, "Санат" көрсеткіш тағайындалған екілік топты білдіреді және "Сенсор_идентификаторы" көрсеткішті жазып алған спектрометрге сілтеме жасайды.

Алдын ала өңдеу фазасында, әсіресе нейрондық желіні талдау үшін спектрлік деректерді дайындау контекстінде қалыпқа келтіру (нормализация) маңызды қадам болып табылады. Бұл процесс айнымалы мәндердің сандық диапазонын реттеуді қамтиды, әрбір белгілер олардың масштабтарындағы тән дисперсияға байланысты үлгіні бұрмалаусыз талдауға бірдей үлес қосады. Бұған қол жеткізу үшін стандартты масштабтау деп аталатын әдіс қолданылады.

Стандартты масштабтау немесе Z-балды қалыпқа келтіру бұл контексте нормализация үшін таңдалатын әдіс болып табылады. Ол белгілерді орташа мәні 0 және стандартты ауытқуы 1 болатындай етіп түрлендіреді. Бұл әрбір белгінің орташа мәнін деректер жиынынан алып тастап, содан кейін нәтижені сол белгінің стандартты ауытқуына бөлу арқылы жүзеге асырылады.

Бақылаудың Z-балын есептеу формуласы келесідей:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

мұндағы x – бақылау мәні, μ – белгінің орташа мәні, және σ – белгінің стандартты ауытқуы.

Қалыпқа келтіру процесі деректер жиынындағы сандық типтегі барлық белгілерге әсіресе, қалқымалы нүкте (float) немесе бүтін сан (integer) түрінде ұсынылғандарға қолданылады. Бұл стандартты масштабтау барлық белгілердің модельдің болжамдық мүмкіндігіне бірдей үлес қосуын қамтамасыз етеді, осылайша үлкен масштабтағы белгілердің модельдің нәтижесіне басым әсер етуін болдырмайды. Бұл әсіресе градиенттік түсуді (gradient descent) оңтайландыру үшін қолданатын модельдерде маңызды, себебі бұл нормализация модельдің жылдам және тиімді түрде жинақталуына (convergence) көмектеседі.

Деректерді қалыпқа келтіру арқылы нейрондық желіге кіріс деректерінен жақсырақ үйренуге және жалпы заңдылықтарды тануға мүмкіндік береді, бұл әсіресе материалдарды олардың спектрлік деректері бойынша классификациялау сияқты міндеттер үшін маңызды. Нормализация қадамы модельдің спектрлік деректерді тиімді өңдеуін және одан үйренуін қамтамасыз етеді, бұл пластиктің немесе талданатын басқа материалдардың әртүрлі түрлерін ажырату қабілетін арттырады.

Нейрондық желі - қабаттарға ұйымдастырылған көптеген өзара байланысты түйіндерден (нейрондардан) тұратын есептеу моделі. Нейрондық желінің негізгі мақсаты мысалдардан үйрену арқылы деректердегі күрделі тәуелділіктерді анықтау болып табылады. Нейрондық желілер сызықты емес функцияларды модельдеуге қабілетті, бұл оларды үлгіні тану, жіктеу және регрессия тапсырмалары үшін тиімді.

Конволюциялық нейрондық желілер (CNN)

CNN - конволюционды қабаттар арқылы деректердегі кеңістіктік иерархияларды автоматты түрде және бейімдеуге арналған терең оқыту архитектурасы. CNN кескінді өндеуде қолдануымен танымал, бірақ сонымен бірге бір өлшемді дәйекті деректерге қолданылады[19].

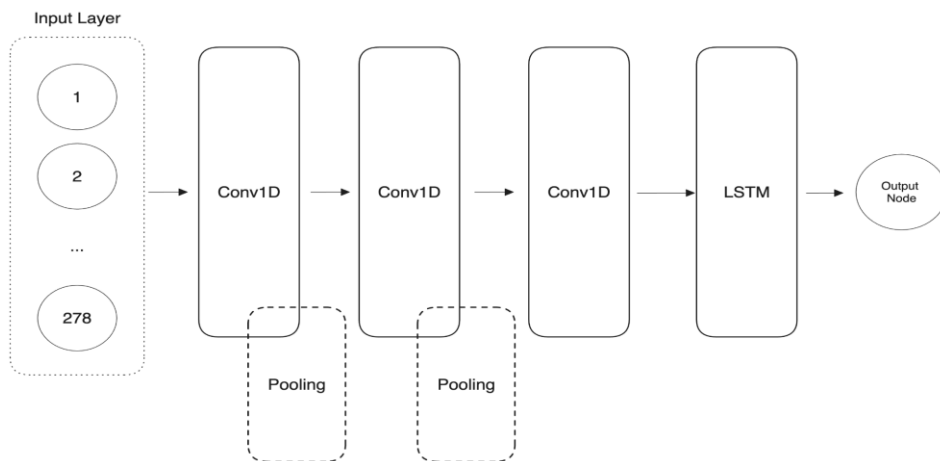
Ұзақ-қысқа мерзімді жад (LSTM)

LSTM — бұл қайталанатын нейрондық желінің (RNN) түрі, ол тізбекті деректерді өндеуге және қарапайым RNN-дерде жиі кездесетін жоғалып кететін градиенттер мәселесін шешуге арналған. LSTM-нің басты ерекшелігі — арнайы басқару элементтері (кіру, шығу және ұмыту "қақпалары"), олар маңызды ақпаратты ұзақ уақыт бойы тиімді сақтауға және жаңартуға мүмкіндік береді.

Бұл мақалада пластикалық қалдықтардың классификациясын жақсарту үшін CNN+LSTM гибриді алгоритм әдістерін қалыпқа келтіру және стандартты масштабтау сияқты деректерді алдын ала өндеу әдістерімен бірге пайдалану қарастырылды.

Конволюциялық нейрондық желілер (CNNs) және ұзақ-қысқа мерзімді жад (LSTM) желілерінің тіркесімі деректердегі кеңістіктік және уақытша үлгілерді пайдалануға арналған қуатты гибриді архитектураны білдіреді. CNN + LSTM архитектурасында LSTM конволюционды қабаттардан кейін қолданылады, мұнда ол CNN шығарған кеңістіктік мүмкіндіктерді дәйекті түрде өңдейді. Бұл құрылым модельге жергілікті кеңістіктік мүмкіндіктерді де, деректердегі уақытша тәуелділіктерді де түсіруге мүмкіндік береді [20].

Конволюциялық қабаттар жергілікті ерекшеліктерді тиімді түрде анықтайды, ал LSTM қабаттары деректер ішіндегі уақыттық тізбектерді түсінуде ерекше нәтиже көрсетеді, бұл классификацияның дәлдігін арттыруға әкеледі. Модель архитектурасына сәйкесінше 3 өлшемді ядросы және 32, 64 және 128 сүзгілер саны бар үш конволюциялық қабаттан тұрады. Әрбір конволюциялық қабат үшін ReLU активация функциясы қолданылды. Алғашқы екі конволюциялық қабаттан кейін деректердің өлшемін азайту үшін пул өлшемі 3 болатын максималды біріктіру (MaxPool) қабаттары қосылды. Содан кейін LSTM қабаты 64 бірлік және қайталанатын оқудан шығару (Dropout) 0.2 қолданылды. Модельдің шығыс қабаты (Output) бинарлы классификация үшін бір нейроннан және Sigmoid активация функциясы бар толық байланысқан қабатпен ұсынылған (сурет-6).



6 сурет – CNN + LSTM моделінің архитектурасы

Өнімділік өлшемі

Әрбір модельдің өнімділігі дәлдік (Accuracy), нақтылық (Precision), еске түсіру (Recall) және F1-есеп (F1-Score) сияқты стандартты метрикаларды пайдалану арқылы бағаланды. Бұл метрикалар модельдің пластикалық қалдықтарды жіктеу тапсырмасының әртүрлі кезеңдерінде классификациялау тиімділігін жан-жақты сипаттап береді.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (2)$$

$$Precision = \frac{TP}{(TP + FP)} \quad (3)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (4)$$

$$F1 - Score = \frac{2 \times (Precision * Recall)}{(Precision + Recall)} \quad (5)$$


Әрбір модель үшін шатастыру матрицалары (confusion matrix) шынайы позитивтер (TP), шынайы негативтер (TN), жалған позитивтер (FP) және жалған негативтер (FN) тұрғысынан өнімділіктің егжей-тегжейлі сипаттамасын береді. Бұл метрикалар әрбір модельдің қай аймақтарда жақсы нәтиже көрсететінін және қай жерлерде жетілдіру қажет екенін түсіну үшін маңызды болып табылады.

Нәтижелер және талқылау.

Бұл зерттеудің негізгі үлесі пластиктің әртүрлі түрлері мен түстерін анықтау, соның ішінде ластанған контейнерлерді анықтау, осылайша пластмассаларды жақын инфрақызыл (NIR) сәйкестендірумен байланысты шектеулерді шешу болып табылады. Пластикалық бөтелкелердің төрт негізгі түрінің NIR спектрлері - полиэтилентерефталат (ПЭТ), жоғары тығыздықтағы полиэтилен (HDPE), төмен тығыздықтағы полиэтилен (LDPE) және полипропилен (PP) - конволюционды нейрондық желіге (CNN) бір өлшемді кіріс ретінде пайдаланылды. Ұсынылған тәсілдің өнімділігін салыстыру үшін логистикалық регрессия, жартылай ең кіші квадраттар (PLS) және сызықтық дискриминанттық талдау (LDA) сияқты бірнеше дәстүрлі алгоритмдер де қолданылды. Әртүрлі әдістерді қолдану арқылы алынған нәтижелер 2-кестеде жинақталған. Әрбір жол белгілі бір кезеңде модельді бағалаудың негізгі көрсеткіштерін көрсетеді.

2 кесте – Төрт әдістің барлық кезеңдер бойынша бағалау көрсеткіштерін салыстыру

Алгоритм түрі	Кезең	Accuracy	Precision	Recall	F1-score
Logistic Regression	1	0.73333	0.55556	1.0	0.71429
	2	0.55	0.5	0.4	0.44444
	3	0.69231	0.6	0.6	0.6
PLS	1	0.66667	0.44444	1.0	0.61538
	2	0.55	0.5	0.4	0.44444
	3	0.69231	0.6	0.6	0.6
LDA	1	0.73333	0.66667	0.85714	0.75
	2	0.54545	0.75	0.42857	0.54545
	3	0.61538	0.6	0.5	0.54545
CNN+ LSTM	1	0.86667	0.77778	1.0	0.875
	2	0.72727	0.5	0.66667	0.57143
	3	0.76923	0.8	0.66667	0.72727



7 сурет – Әртүрлі әдістер арасындағы дәлдік көрсеткіштерін салыстыру нәтижесі

2-кесте мен 7-суреттен көрініп тұрғандай, CNN+LSTM моделі пластикалық контейнерлерді классификациялауда жоғары тиімділікті көрсетті, дәстүрлі әдістермен салыстырғанда (мысалы, Логистикалық регрессия, PLS және LDA) жоғары нәтиже берді.


1-кезеңде, яғни PET бөтелкелері мен контейнерлердің әртүрлі түрлері, сондай-ақ тұрмыстық химияда жиі қолданылатын PP, HDPE және LDPE пластикалық контейнерлері қамтылған жағдайда, CNN+LSTM моделі дәлдік (accuracy) 0.86667, нақтылық (precision) 0.77778, қамту (recall) 1.0 және F1-өлшемі 0.875 көрсетті. Бұл нәтиже PET пен басқа полимерлер арасындағы спектрлік айырмашылықтар айқын болған кезде модельдің жоғары классификация қабілетін көрсетеді.

2-кезеңде түссіз (мөлдір - transparent) және түрлі-түсті пластикалық заттарды қамтыды, олар PET немесе PP болуы мүмкін. Бұл кезеңде жартылай түссіз және толық түссіз бөтелкелер арасындағы спектрлік айырмашылықтардың аз болуы, яғни түссіз пластмасы байланысты модель кейбір қиындықтарға тап болды. Осы себепті өнімділік төмендеп, CNN+LSTM моделі үшін дәлдік 0.72727, нақтылық 0.5, қамту 0.66667 және F1-өлшемі 0.57143 деңгейіне жетті. Дәстүрлі әдістер: Логистикалық регрессия мен PLS төменірек нәтижелер көрсетті, бұл олардың спектрлік айырмашылықтарды ажырату қабілетінің шектеулі екенін көрсетті. Себебі, түссіз немесе жартылай мөлдір пластиктер (PET, PP) жарықты жұту (абсорбция) және шағылысу (рефлексия) процестері төмен болғандықтан, NIR спектрометрінде әлсіз сигнал береді. Дегенмен машиналық оқыту алгоритмдері арқылы бар сигналмен классификация жасауға болатынын көреміз. Ал түсті немесе тығыз пластиктер жарықты көбірек сіңіретіндіктен, олардың спектрлік сигналдары айқын және классификация нәтижелері жоғары болады.

3-кезеңде классификация таза PET бөтелкелер мен тамақ өнімдерінің немесе қауіпті сұйықтықтардың қалдықтарымен ластанған бөтелкелер арасында жүргізілді. Бұл жағдайда әртүрлі ластану деңгейіне байланысты кластар арасындағы айырмашылықтар өзгеріп отырды. Ластану деңгейі өте төмен немесе көзге көрінбейтін зиянды заттар бар бөтелкелер тек аздаған спектрлік айырмашылықтарды көрсетті, бұл классификацияның дәлдігін төмендетті. Осы кезеңде ұсынылған CNN+LSTM моделі 76.923% дәлдік, 80% нақтылық, 66.667% қамту және 72.727 F1-өлшемін көрсетті. Дәстүрлі әдістердің де дәлдік көрсеткіштері төмендегенін байқауға болады. Бұның негізгі себептерінің бірі ол бөтелкенің жоғарыда айтылғандай түссіз болуы, сондай-ақ кейбір үлгілерде контейнерге құйылған зиянды сұйықтықтардың да түссіз болуы (бензин, түссіз химиялық гельдер) және

қалдықтардың толық бөтелкеде жайылмауы, яғни қалдықтың жартылай болуы секілді факторлар әсер етеді.

Сонымен қатар, 8-суретте көрсетілгендей, модельдің әртүрлі классификация шектері бойынша өнімділігін бағалау үшін ROC қисығы жасалды. Нәтижелер әртүрлі пластикалық қалдықтардың ішіндегі әртүрлі полимерлерді дәл жіктеуде ұсынылған алгоритмнің тиімділігін көрсетеді.



8 сурет – Барлық кезең бойынша ROC қисығы

Әрбір модельдің ROC қисықтары шекті мәндердің өзгеруіне байланысты нақты оң көрсеткіштер (сезімталдық) және жалған оң көрсеткіштер (1 – ерекшелік) арасындағы қатынасты көрсетеді. "Receiver Operating Characteristic" қисығының астындағы (AUC) аудан модельдің класстарын ажырату қабілетін бір ғана мән арқылы бағалауға мүмкіндік береді. AUC мәнінің жоғары болуы классификатордың класстарды жақсы ажырата алатынын білдіреді.

Осылайша, зерттеу нәтижелері CNN+LSTM моделінің пластикалық қалдықтарды классификациялау кезінде дәстүрлі әдістерге қарағанда жоғары дәлдік көрсететінін ғылыми тұрғыдан дәлелдеді, әсіресе 1-кезеңде, спектрлік контраст жоғары болды. Алайда, спектрлік айырмашылықтар азайған сайын, әсіресе жартылай мөлдір және ластанған пластиктер

арасында, модельдің өнімділігі төмендейді, бұл аз мөлшерде ластанған материалдарды ажыратудың күрделілігін көрсетеді. Бұл нәтижелер CNN+LSTM сияқты терең нейрондық желі архитектураларының сұрыптау және қайта өңдеу міндеттеріне тиімді екенін растайды, сондай-ақ ұсынылған тәсілдің күрделі классификация мәселелерінде дәстүрлі әдістермен салыстырғанда жоғары дәлдік пен сенімділікке ие екенін дәлелдейді.

Қорытынды.

Бұл зерттеуде жақын инфрақызыл (NIR) спектроскопиясы арқылы алынған спектрлік деректер негізіндегі пластикалық қалдықтарды классификациялау үшін CNN+LSTM моделі әзірленіп, сынақ жасалды. Нәтижелер бұл модельдің логистикалық регрессия, ішінара ең кіші квадраттар (PLS) және сызықтық дискриминанттық талдау (LDA) сияқты дәстүрлі әдістермен салыстырғанда, әсіресе спектрлік айырмашылықтары төмен немесе ластануы бар пластмассаларды жіктеуде белгілі бір артықшылықтары бар екенін көрсетеді. Модельдің жоғары классификация дәлдігі оның кеңістіктік және уақыттық ерекшеліктерді тиімді түрде бөліп алу қабілетімен түсіндіріледі, бұл материалдың негізгі қасиеттерін дәл анықтауға мүмкіндік береді.

CNN+LSTM моделінің сұрыптаудың бастапқы кезеңіндегі өнімділігі ең жоғары болды, себебі бұл кезеңде ПЭТ пен басқа пластиктер арасындағы спектрлік айырмашылықтар айқын байқалды. Осы кезеңде модель дәлдік, нақтылық және F1-өлшемі бойынша ең жоғары көрсеткіштерге жетті, бұл оның материалдардың спектрлік қолтаңбалары айқын болған жағдайда тиімді екенін дәлелдейді. Алайда, жартылай мөлдір немесе ластанған пластиктерді ажырату кезінде модельдің өнімділігі төмендеді, себебі бұл материалдардың спектрлері арасындағы айырмашылықтар аз болды. Бұл шектеулер спектрлік деректерді өңдеу және модель архитектурасын жетілдіру қажеттілігін көрсетеді.

Болашақ зерттеулер спектрлік деректердің дәлдігін арттыру үшін гиперспектралды бейнелеуді енгізуге және алдын ала өңдеу әдістерін жетілдіруге бағытталатын болады. Қазіргі таңда қолданылған белгілерді бөліп алу және нормализация әдістеріне қарамастан, неғұрлым күрделі деректерді өңдеу тәсілдері модельдің спектрлік айырмашылықтарды дәлірек анықтауына мүмкіндік беруі ықтимал, бұл әсіресе ластанған немесе визуалды ұқсас пластиктерді жақсы ажыратуға ықпал етеді. Сонымен қатар, болашақ зерттеулер Transformer негізіндегі архитектураларды зерттеуге және қалдықтарды сұрыптаудың әртүрлі жағдайларында модельдің нақтылығын арттыруға бағытталатын болады. Бұл технологияларды одан әрі дамыту автоматтандырылған пластикалық қалдықтарды сұрыптау жүйелерін жетілдіруге және тұрақты қайта өңдеу процестерін дамытуға ықпал етеді.

Ұсынылған әдістің практикалық маңыздылығы жоғары, оны пластикалық қалдықтарды сұрыптаудың автоматтандырылған жүйелерінде қолдануға болады. Әдіс авиациялық салада қалдықтарды сұрыптау жүйелеріне енгізу үшін де қолдануға болады. Әуежайларда және әуе кемелерінде жиналатын пластик қалдықтарды автоматтандырылған түрде сұрыптау қайта өңдеу процестерінің тиімділігін арттыруға ықпал етіп, экологиялық тұрақтылыққа қолдау көрсете алады.

Алғыс білдіру. Бұл зерттеу жұмысы Қазақстан Республикасы Ғылым және жоғары білім министрлігі Ғылым комитетінің қаржылай қолдауымен жүзеге асырылды (грантық қаржыландыру АР22685518 ғылыми жобасы).

Әдебиеттер

1. Анализ размера и доли рынка пластиковой упаковки – тенденции роста и прогнозы (2024–2029 гг.) Дереккөз: <https://www.mordorintelligence.com/ru/industry-reports/plastic-packaging-market> [Қол жетімділік: 2024 жылдың 10 қазан]

2. Bonifazi, G., Capobianco, G., & Serranti, S. (2018). A hierarchical classification approach for recognition of low-density (LDPE) and high-density polyethylene (HDPE) in mixed plastic waste based on short-wave infrared (SWIR) hyperspectral imaging. *Spectrochimica Acta - Part A: Molecular and Biomolecular Spectroscopy*, *198*, 115–122. <https://doi.org/10.1016/j.saa.2018.03.006>
3. Gent, M., Sierra, H. M., Álvarez, M. M., & McCulloch, J. (2018). An evaluation of hydrocyclones and the LARCODEMS cylindrical cyclone for the separation of waste plastics of proximate densities. *Waste Management*, *79*, 374–384. <https://doi.org/10.1016/j.wasman.2018.08.004>
4. Zhang, Y., Wang, Q., Yalikun, N., Wang, H., Wang, C., & Jiang, H. (2023). A comprehensive review of separation technologies for waste plastics in urban mine. *Resources, Conservation & Recycling*, *197*, 107087. <https://doi.org/10.1016/j.resconrec.2023.107087>
5. Ragaert, K., Delva, L., & Van Geem, K. (2017). Mechanical and chemical recycling of solid plastic waste. *Waste Management*, *69*, 24–58. <https://doi.org/10.1016/j.wasman.2017.07.044>
6. Gundupalli, S. P., Hait, S., & Thakur, A. (2017). A review on automated sorting of source-separated municipal solid waste for recycling. *Waste Management*, *60*, 56–74. <https://doi.org/10.1016/j.wasman.2016.09.015>
7. Shameem, K. M. M., Choudhari, K. S., & Bankapur, A. (2017). A hybrid LIBS–Raman system combined with chemometrics: an efficient tool for plastic identification and sorting. *Analytical and Bioanalytical Chemistry*, *409*, 3299–3308. <https://doi.org/10.1007/s00216-017-0268-z>
8. Brunner, S., Fomin, P., & Kargel, C. (2015). Automated sorting of polymer flakes: fluorescence labeling and development of a measurement system prototype. *Waste Management*, *38*, 49–60. <https://doi.org/10.1016/j.wasman.2014.12.006>
9. Safavi, S. M., Masoumi, H., & Mirian, S. (2010). Sorting of polypropylene resins by color in MSW using visible reflectance spectroscopy. *Waste Management*, *30* (11), 2216–2222. <https://doi.org/10.1016/j.wasman.2010.06.023>
10. Kumar, S., Yadav, D., Gupta, H., Verma, O. P., Ansari, I. A., & Ahn, C. W. (2021). A novel YOLOv3 algorithm-based deep learning approach for waste segregation: Towards smart waste management. *Electronics*, *10*(1), 14. <https://doi.org/10.3390/electronics10010014>
11. Tan, Z., Fei, Z., Zhao, B., Yang, J., Xu, X., & Wang, Z. (2021). Identification for recycling polyethylene terephthalate (PET) plastic bottles by polarization vision. *IEEE Access*, *9*, 27510–27517. <https://doi.org/10.1109/ACCESS.2021.3050816>
12. Ahmed, M. I. B., Alotaibi, R. B., Al-Qahtani, R. A., Al-Qahtani, R. S., Al-Hetela, S. S., Al-Matar, K. A., ... & Youldash, M. (2023). Deep learning approach to recyclable products classification: Towards sustainable waste management. *Sustainability*, *15*, 11138. <https://doi.org/10.3390/su151411138>
13. Singh, M. K., Hait, S., & Thakur, A. (2023). Hyperspectral imaging-based classification of post-consumer thermoplastics for plastics recycling using artificial neural network. *Process Safety and Environmental Protection*, *179*, 593–602. <https://doi.org/10.1016/j.psep.2023.09.052>
14. Qiu, Z., Zhao, S., Feng, X., & He, Y. (2020). Transfer learning method for plastic pollution evaluation in soil using NIR sensor. *Science of the Total Environment*, *740*, 140118. <https://doi.org/10.1016/j.scitotenv.2020.140118>
15. Marchesi, C., Rani, M., Federici, S., Lancini, M., & Depero, L. E. (2023). Evaluating chemometric strategies and machine learning approaches for a miniaturized near-infrared spectrometer in plastic waste classification. *Acta IMEKO*, *12*(2), 1–7. <https://doi.org/10.21014/actaimeko.v12i2.1531>

16. Masoumi, H., Safavi, S. M., & Khani, Z. (2012). Identification and classification of plastic resins using near infrared reflectance spectroscopy. *International Journal of Mechanical and Industrial Engineering*, 6, 213–220.

17. Xia, J., Huang, Y., Li, Q., Xiang, Y., & Min, Sh. (2021). Convolutional neural network with near-infrared spectroscopy for plastic discrimination. *Environmental Chemistry Letters*, 19, 3547–3555. <https://doi.org/10.1007/s10311-021-01240-9>

18. Olowolayemo, A., Radzi, N. I. A., & Ismail, N. F. (2022). Classifying plastic waste using deep convolutional neural networks for efficient plastic waste management. *International Journal on Perceptive and Cognitive Computing*, 8(2), 6–15. <https://doi.org/10.5281/zenodo.6457607>

References

1. Analiz obema i doli rynka plastikovoj upakovki – tendencii rosta i prognozy (2024–2029 gg.) Retrieved October 10, 2024, from <https://www.mordorintelligence.com/industry-reports/plastic-packaging-market>

2. Bonifazi, G., Capobianco, G., & Serranti, S. (2018). A hierarchical classification approach for recognition of low-density (LDPE) and high-density polyethylene (HDPE) in mixed plastic waste based on short-wave infrared (SWIR) hyperspectral imaging. *Spectrochimica Acta - Part A: Molecular and Biomolecular Spectroscopy*, 198, 115–122. <https://doi.org/10.1016/j.saa.2018.03.006>

3. Gent, M., Sierra, H. M., Álvarez, M. M., & McCulloch, J. (2018). An evaluation of hydrocyclones and the LARCODEMS cylindrical cyclone for the separation of waste plastics of proximate densities. *Waste Management*, 79, 374–384. <https://doi.org/10.1016/j.wasman.2018.08.004>

4. Zhang, Y., Wang, Q., Yalikun, N., Wang, H., Wang, C., & Jiang, H. (2023). A comprehensive review of separation technologies for waste plastics in urban mine. *Resources, Conservation & Recycling*, 197, 107087. <https://doi.org/10.1016/j.resconrec.2023.107087>

5. Ragaert, K., Delva, L., & Van Geem, K. (2017). Mechanical and chemical recycling of solid plastic waste. *Waste Management*, 69, 24–58. <https://doi.org/10.1016/j.wasman.2017.07.044>.

6. Gundupalli, S. P., Hait, S., & Thakur, A. (2017). A review on automated sorting of source-separated municipal solid waste for recycling. *Waste Management*, 60, 56–74. <https://doi.org/10.1016/j.wasman.2016.09.015>

7. Shameem, K. M. M., Choudhari, K. S., & Bankapur, A. (2017). A hybrid LIBS–Raman system combined with chemometrics: an efficient tool for plastic identification and sorting. *Analytical and Bioanalytical Chemistry*, 409, 3299–3308. <https://doi.org/10.1007/s00216-017-0268-z>

8. Brunner, S., Fomin, P., & Kargel, C. (2015). Automated sorting of polymer flakes: fluorescence labeling and development of a measurement system prototype. *Waste Management*, 38, 49–60. <https://doi.org/10.1016/j.wasman.2014.12.006>

9. Safavi, S. M., Masoumi, H., & Mirian, S. (2010). Sorting of polypropylene resins by color in MSW using visible reflectance spectroscopy. *Waste Management*, 30 (11), 2216–2222. <https://doi.org/10.1016/j.wasman.2010.06.023>

10. Kumar, S., Yadav, D., Gupta, H., Verma, O. P., Ansari, I. A., & Ahn, C. W. (2021). A novel YOLOv3 algorithm-based deep learning approach for waste segregation: Towards smart waste management. *Electronics*, 10(1), 14. <https://doi.org/10.3390/electronics10010014>

11. Tan, Z., Fei, Z., Zhao, B., Yang, J., Xu, X., & Wang, Z. (2021). Identification for recycling polyethylene terephthalate (PET) plastic bottles by polarization vision. *IEEE Access*, 9, 27510–27517. <https://doi.org/10.1109/ACCESS.2021.3050816>

12. Ahmed, M. I. B., Alotaibi, R. B., Al-Qahtani, R. A., Al-Qahtani, R. S., Al-Hetela, S. S., Al-Matar, K. A., ... & Youldash, M. (2023). Deep learning approach to recyclable products

classification: Towards sustainable waste management. *Sustainability*, 15, 11138. <https://doi.org/10.3390/su151411138>

13. Singh, M. K., Hait, S., & Thakur, A. (2023). Hyperspectral imaging-based classification of post-consumer thermoplastics for plastics recycling using artificial neural network. *Process Safety and Environmental Protection*, 179, 593–602. <https://doi.org/10.1016/j.psep.2023.09.052>

14. Qiu, Z., Zhao, S., Feng, X., & He, Y. (2020). Transfer learning method for plastic pollution evaluation in soil using NIR sensor. *Science of the Total Environment*, 740, 140118. <https://doi.org/10.1016/j.scitotenv.2020.140118>

15. Marchesi, C., Rani, M., Federici, S., Lancini, M., & Depero, L. E. (2023). Evaluating chemometric strategies and machine learning approaches for a miniaturized near-infrared spectrometer in plastic waste classification. *Acta IMEKO*, 12(2), 1-7. <https://doi.org/10.21014/actaimeko.v12i2.1531>

16. Masoumi, H., Safavi, S. M., & Khani, Z. (2012). Identification and classification of plastic resins using near infrared reflectance spectroscopy. *International Journal of Mechanical and Industrial Engineering*, 6, 213–220.

17. Xia, J., Huang, Y., Li, Q., Xiang, Y., & Min, Sh. (2021). Convolutional neural network with near-infrared spectroscopy for plastic discrimination. *Environmental Chemistry Letters*, 19, 3547–3555. <https://doi.org/10.1007/s10311-021-01240-9>

18. Olowolayemo, A., Radzi, N. I. A., & Ismail, N. F. (2022). Classifying plastic waste using deep convolutional neural networks for efficient plastic waste management. *International Journal on Perceptive and Cognitive Computing*, 8(2), 6–15. <https://doi.org/10.5281/zenodo.6457607>

NEURAL NETWORK APPLICATION FOR OPTIMIZING THE SORTING PROCESS OF POLYMER CONTAINERS

Abstract. This study investigates the use of a hybrid neural network architecture that combines convolutional neural networks (CNN) and long short-term memory (LSTM) for efficient sorting of plastic containers. The study focuses on classifying plastic waste based on chemical composition and contamination level, obtained with a near-infrared (NIR) spectroscopy device. Experimental results show that the CNN+LSTM hybrid model achieves relatively high accuracy in recognizing different types and colors of plastics, including the detection of contaminants in containers. A comparative evaluation of the model's performance was conducted with traditional classification methods such as logistic regression, partial least squares (PLS), and linear discriminant analysis (LDA). The results show that the CNN+LSTM model performs better than traditional approaches, especially in scenarios with small spectral differences between classes. This study demonstrates the potential of machine learning to improve the efficiency of plastic waste sorting and recycling processes, thereby contributing to improved environmental sustainability.

Keywords. Plastic waste, NIRS (Near-infrared spectroscopy), Neural network, Hybrid model, CNN, LSTM.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОПТИМИЗАЦИИ ПРОЦЕССА СОРТИРОВКИ ПОЛИМЕРНЫХ КОНТЕЙНЕРОВ

Аннотация. В этом исследовании рассматривается использование архитектуры гибридной нейронной сети, сочетающей сверточные нейронные сети (CNN) и долговременную память (LSTM), для эффективной сортировки пластиковых контейнеров. Исследование было сосредоточено на классификации пластиковых отходов на основе химического состава и уровня загрязнения, полученной с помощью спектроскопического устройства ближнего инфракрасного диапазона (NIR). Результаты экспериментов показывают, что гибридная модель CNN+LSTM обеспечивает относительно высокую

точность распознавания различных типов и цветов пластика, включая обнаружение загрязняющих веществ в контейнерах. Сравнительная оценка производительности модели проводилась с использованием традиционных методов классификации, таких как логистическая регрессия, частичные наименьшие квадраты (PLS) и линейный дискриминантный анализ (LDA). Результаты показывают, что модель CNN+LSTM работает лучше, чем традиционные подходы, особенно в сценариях с небольшими спектральными различиями между классами. Это исследование демонстрирует потенциал машинного обучения для повышения эффективности процессов сортировки и переработки пластиковых отходов, тем самым способствуя повышению экологической устойчивости.

Ключевые слова. Пластиковые отходы, NIRS (ближняя инфракрасная спектроскопия), Нейронная сеть, Гибридная модель, CNN, LSTM.

Авторлар туралы мәлімет

Алимбекова Назым Ахатовна	магистр, компьютерлік және программалық инженерия кафедрасы, Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан, E-mail: nazakhatovna@gmail.com
Хари Мохан Рай	PhD, Компьютер ғылымдар мектебі, Гачон университеті, Соннам, Оңтүстік Корея, E-mail: drhmrai@gachon.ac.kr
Турымбетов Турсинбай Абдибекович	Қауымдастырылған профессор міндетін атқарушы, техника ғылымдарының кандидаты, гуманитарлық мектеп, Халықаралық туризм және меймандостық университеті, Түркістан, Қазақстан, E-mail: t.turimbetov@iuth.edu.kz
Жумадилаева Айнура Канадиловна	Техника ғылымдарының кандидаты, доцент, компьютерлік және программалық инженерия кафедрасы, Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан, E-mail: zhumadillayeva_ak@enu.kz

Сведения об авторах

Алимбекова Назым Ахатовна	Магистр, Кафедра компьютерной и программной инженерии, Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан, E-mail: nazakhatovna@gmail.com
Хари Мохан Рай	PhD, доцент, Школа компьютерных наук, Университет Гачон, Соннам, Южная Корея, E-mail: drhmrai@gachon.ac.kr
Турымбетов Турсинбай Абдибекович	И.о. ассоциированного профессора, кандидат технических наук, гуманитарная школа, международный университет туризма и гостеприимства, E-mail: t.turimbetov@iuth.edu.kz
Жумадилаева Айнура Канадиловна	Доцент, кандидат технических наук, кафедра компьютерной и программной инженерии, Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан, E-mail: zhumadillayeva_ak@enu.kz

Information about the authors

Nazym Alimbekova	Department of Computer and Software Engineering, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan, E-mail: nazakhatovna@gmail.com
Hari Mohan Rai	PhD, Associate Professor, School of Computing, Gachon University, Seong-nam-si, South Korea, E-mail: drhmrai@gachon.ac.kr
Tursinbay Turymbetov	Acting Associate Professor, PhD in Engineering, Humanities school, International University of Tourism and Hospitality, Turkistan, Kazakhstan; E-mail: t.turimbetov@iuth.edu.kz
Ainur Zhumadillayeva	Associate Professor, PhD in Engineering, Department of Computer and Software Engineering, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan, E-mail: zhumadillayeva_ak@enu.kz