



Ғылыми мақала

НЕЙРОНДЫҚ ЖЕЛІЛІК МОДЕЛЬДЕРДІ ПАЙДАЛАНА ОТЫРЫП, PLANETSCORE КЕСКІНДЕРІНЕ НЕГІЗДЕЛГЕН ЖЕРЛЕРДІҢ МҰНАЙМЕН ЛАСТАНУЫН СЕМАНТИКАЛЫҚ СЕГМЕНТТЕУ

Ғалымжан С. Әбдіманап*^{id}, Татьяна В. Дедова^{id} техника ғылымдарының кандидаты, Лариса А. Балакай^{id} техника ғылымдарының кандидаты, Данияр Б. Нурсеитов^{id} физика-математика ғылымдарының кандидаты, Серик М. Нурақынов¹^{id} PhD

ЖШС «Ионосфера институты», Алматы қ., Қазақстан; g.s.abdimanap@gmail.com (Ғ.С.Ә.), dedova3007@gmail.com (Т.В.Д.), larissabalakay@gmail.com (Л.А.Б.), nurseitovdb@gmail.com (Д.Б.Н.)

*Автор корреспонденция: Ғалымжан С. Әбдіманап, g.s.abdimanap@gmail.com

ТҮЙІН СӨЗДЕР

мұнаймен ластанған аумақтар, қашықтықтан зондтау, PlanetScore, терең оқыту, семантикалық сегментация

АБСТРАКТ

Жерлердің мұнаймен ластануын бақылау Қазақстан үшін өзекті мәселе болып табылады. Кеңестік кезеңде кейбір кен орындарында мұнай өндіру «амбарлық» әдіспен жүргізілді: бұрғылау қалдықтары, технологиялық сұйықтықтар және ілеспе ағынды сулар өндіру орнының жанында арнайы қазылған амбарларға жинақталды, нәтижесінде рекультивация мен бақылауды қажет ететін мұнаймен ластанған аумақтар едәуір жинақталып қалды. Қашықтан зондтау әдістері терең оқыту алгоритмдерімен бірлесіп қолданғанда ластанған аумақтарды дәлірек сегменттеуге және бақылауға мүмкіндік береді. Бұл жұмыста шағын ауданды мұнай ластануларын сегменттеуге арналған, PlanetScore мультиспектрлік түсірілімдері негізінде қалыптастырылған ROSID-HR деректер жиыны ұсынылады. ROSID-HR жасау кезінде бұрын әзірленген ROSID деректер жиынындағы мұнаймен ластанған учаскелер эталондық белгілеу ретінде пайдаланылды, бұл екі деректер жиыны арасындағы аннотация дәйектілігін қамтамасыз етті. Эксперименттер арқылы мұнаймен ластанған аумақтарды көлеңкелер мен техногендік нысандардан тиімдірек ажырату үшін PlanetScore арналарының оңтайлы конфигурациясы Blue-Red-NIR (2-6-8) айқындалды. Деректер жиынының жұмысқа қабілеттілігін тексеру үшін классикалық DeepLabv3+ және трансформерлік Mask2Former модельдері арқылы семантикалық сегментация жүргізілді. Mask2Former архитектурасы тестілік жиында «мұнай» класы үшін IoU мәнін 69,73%-ке жеткізді, бұл DeepLabv3+ моделінің нәтижесінен (21,63%) үш еседен астам жоғары. Нәтижелер шағын ауданды мұнаймен ластанған учаскелерді анықтауда PlanetScore деректері мен Mask2Former архитектурасын бірлесіп қолданудың қарастырылған тәсілдер шеңберіндегі тиімділігі мен артықшылығын растайды.

1. КІРІСПЕ

Мұнай өндіру, сақтау немесе тасымалдау барысында құрлықта мұнайдың төгілуі мен мұнаймен ластанған жерлердің пайда болуы топырақтың табиғи химиялық тепе-теңдігінің бұзылуына әкелетін ауыр экологиялық салдарларға соқтырады. Мұнайдың топырақтың үстіңгі қабатында жинақталуы оның биологиялық белсенділігінің төмендеуіне, су-ауа режимінің нашарлауына, өсімдіктердің қалыпты өсуінің тежелуіне, сондай-ақ биоценоздардағы өзгерістерге, яғни түрлер арасында қалыптасқан байланыстардың бұзылуына әкеледі. Топырақ экожүйесінің тұтастай тұрақтылығы айтарлықтай төмендейді, сонымен қатар топырақтың өздігінен қалпына келу қабілеті де кемиді [1].

Қазақстан үшін мұнай төгінділері мәселесі ерекше өткір тұр. Мұнаймен ластанған топырақтардың едәуір бөлігі кеңестік кезеңнен бастап мұнай өндірудің негізгі аймағы болып келе жатқан Каспий өңірінде шоғырланған [2]. Ең көп зардап шеккен аудандарда мұнай өнімдерінің концентрациясы 172 480 мг/кг-ға жетеді, бұл Қазақстанда белгіленген 100 мг/кг рұқсат етілген шекті концентрациядан бірнеше есе асып түседі [3]. Мұндай учаскелердің көп бөлігі кеңестік кезеңнің тарихи ластануларына жатады, ол кезде қалдықтар тиісінше сақталмай, ашық полигондарға үйілген немесе тікелей топыраққа, су айдындарына не арнайы ұйымдастырылған резервуарларға төгілген. Соңғы жылдары Қазақстанның мұнай өндіруші компаниялары мұнаймен ластанған аумақтарды рекультивациялау бойынша жұмыстар жүргізіп жатқанымен, мұндай учаскелерді анықтаудың тиімді әдістерін әзірлеу қажеттілігі сақталуда. Бұл рекультивация процесінің өзін де, оны кейіннен бақылауды жоспарлау үшін қажет.

Жерді қашықтан зондтау (ЖҚЗ) әдістері, оның ішінде спутниктік бақылаулар мен аэрофототүсірілім, топырақтың мұнаймен ластануын картографиялаудың тиімді құралдары болып табылады [4]. Мұнаймен ластанған аумақтарды дешифрлеудің бірнеше әдісі бар. [5] жұмыста топырақ температурасын бағалау үшін интерполяция мен градиенттік талдау әдістері қолданылды, бұл мұнай ластануларымен байланысты термиялық ауытқуларды анықтауға мүмкіндік береді. Бірқатар жұмыстарда топырақтың мұнаймен ластануын анықтау үшін спектрлік индекстер мен машиналық оқыту әдістері пайдаланылды [6]. Кувейттің аудандарындағы мұнай төгінділерін бақылауға арналған [7] зерттеуде мультиспектрлік деректерді жіктеу үшін тірек векторлар әдісі (SVM) мен кездейсоқ ормандар (RF) әдістері қолданылды. Зерттеу нәтижелері анықтау сапасына әдістерді таңдаудан гөрі пайдаланылған спутниктік деректердің спектрлік ажыратымдылығы көбірек әсер ететінін көрсетті.

Конволюциялық нейрондық желілердің (CNN) пайда болуы спутниктік түсірілімдерді дешифрлеу тәсілдерін айтарлықтай өзгертті. CNN мұнайды танып-білуді өзі үйренеді; ол оқыту жинағында жинақталған мысалдардан акпаратты автоматты түрде бөліп алады [8, 9]. Сондықтан мұндай деректер жинақтарының көлемі мен дәлдігіне қойылатын талап арта түседі. Алайда құрлықтағы мұнай төгінділері саласында сапалы белгіленген деректер әлі де аз [10].

Біздің алдыңғы зерттеуімізде Landsat спутниктік түсірілімдері негізінде ROSID деректер жинағы әзірленіп, жарияланған болатын [11]. ROSID 9 класс бойынша аннотацияларды ұсынып, PSPNet, DeepLabv3, DeepLabv3+, UNet және Mask2Former сияқты архитектуралар үшін базалық дәлдік көрсеткіштерін (benchmarks) белгіледі. Жүргізілген эксперименттердің нәтижелері бойынша конволюциялық нейрондық желілер арасындағы ең жоғары көрсеткіштерді DeepLabv3 + архитектурасы көрсетті, ал Mask2Former трансформаторлық архитектурасы ең жақсы жалпы нәтижені көрсетті. Алайда орташа ажыратымдылықтағы түсірілімдерді пайдалану ауданы шағын мұнаймен ластанған аумақтарды анықтауға белгілі бір шектеулер қояды. Бұл Кеңістіктік ажыратымдылығы жоғары деректерде терең оқыту әдістерін сынақтан өткізуді қажет етеді. Сонымен қатар, орташа ажыратымдылық деректерінен алынған нәтижелер конволюциялық немесе трансформаторлық тәсілдердің артықшылықтары қаншалықты тиімді екенін нақты бағалауға мүмкіндік бермейді. Осыған байланысты, бұл жұмыс зерттеудің келесі кезеңін ұсынады, оның шеңберінде әртүрлі модельдер отбасыларына жататын ең тиімді екі архитектура, конволюциялық (DeepLabv3+) және трансформаторлық (Mask2Former), PlanetScore 3-5 м кеңістіктік ажыратымдылықтағы суреттерінен құрылған жаңа ROSID-HR деректер жиынтығында оқытылады және сыналады. Жоғары кеңістіктік ажыратымдылықтағы қашықтықтан зондтау деректеріндегі осы салыстырмалы талдаудың нәтижелері ластанған аумақтарды тануға арналған жасанды нейрондық желінің мамандандырылған моделін кейіннен әзірлеу үшін ең перспективалы архитектуралық тәсілді анықтау үшін негіз болады.

2. МАТЕРИАЛДАР ЖӘНЕ ӘДІСТЕР

Мақала жайында:

Алынды: 10.06.2026

Қайта қаралды: 16.07.2026

Қабылданды: 17.09.2026

Жарияланды: 30.09.2026

Для цитирования:

Әбдіманап Ғ.С., Дедова Т.В.,

Балакай Л.А., Нурсеитов Д.Б.,

Нуракинов С.М., Нейрондық

желілік модельдерді

пайдалана отырып,

PlanetScore кескіндеріне

негізделген жерлердің

мұнаймен ластануын

семантикалық сегменттеу //

Гидрометеорология және

экология, 123 (3), 2026, 289–

303.

Зерттеу ауданын таңдау авторлардың алдыңғы жұмысының нәтижелерімен негізделді. Ол жұмыста орташа кеңістіктік ажыратымдылықтағы (30 м) Landsat спутниктік деректері негізінде Маңғыстау облысының мұнай кен орындары аумағындағы мұнаймен ластанған жерлер анықталған еді. Бұл кен орындарында бұрғылаудың «амбарлық» әдісі кеңінен қолданылды; яғни бұрғылау қалдықтары мен ағынды сулар ұңғымалардың жанында арнайы қазылған амбарларға жинақталды.

Осы зерттеу шеңберінде PlanetScore тобының жоғары кеңістіктік ажыратымдылықтағы оптикалық спутниктік түсірілімдері негізінде жаңа оқыту деректер жинағы (ROSID-HR) қалыптастырылды. Алдыңғы зерттеуде анықталған мұнай ластануының учаскелері (ROSID деректер жинағы) аннотацияланған кескіндерді қалыптастыру кезінде эталондық белгілеу ретінде пайдаланылды, бұл ластанған аумақтардың кеңістіктік шекараларын нақтылауға және жоғары ажыратымдылықтағы жаңа оқыту деректерін жасауға мүмкіндік берді.


PlanetScore оптикалық түсірілімдерінің кеңістіктік ажыратымдылығы 3...5 м, бұл бұрын пайдаланылған Landsat деректерінен (30 м) едәуір жоғары. 2022 жылдан бастап PlanetScore спутниктік тобын жаңғырту шеңберінде жетілдірілген SuperDove сенсорлары қолданылады; олар 8 спектрлік арнада мультиспектрлік кескіндер алуды қамтамасыз етеді: coastal blue (жағалаулық көк), blue (көк), green I, green (жасыл), yellow (сары), red (қызыл), red-edge (қызыл шекара) және near-infrared (NIR, жақын инфрақызыл). PlanetScore түсірілімдерінің 3...5 м кеңістіктік ажыратымдылығы шағын нысандар мен бет біркелкісіздіктерін егжей-тегжейлі талдауға жеткілікті. Бұған қоса, SuperDove сенсорларының red-edge және NIR арналарын қамтитын кеңейтілген спектрлік жиынтығы жер беті түрлерін, өсімдік жамылғысының күй-жайын және мұнаймен ластанған учаскелерді дәлірек ажыратуға мүмкіндік береді.

Жоғары ажыратымдылықтағы спутниктік түсірілімдерді өңдеу процесі келесі кезеңдерден тұрды (1-сурет):

- Бастапқы деректерді іріктеу. Зерттеу ауданы үшін PlanetScore спутниктерінің 2017...2024 жж. аралығындағы бұлттылығы ең төмен түсірілімдері жылына үш мозаика жиілігімен іріктелді. Нәтижесінде ауданы шамамен 540 км² кен орнының аумағын қамтитын 24 мозаика және ауданы шамамен 550 км² кен орнының аумағын қамтитын 8 мозаикадан тұратын деректер жиынтығы қалыптастырылды.
- Бастапқы түсірілімдерді алдын ала жіктеу EM Cluster Analysis әдісі арқылы жүргізілді: мұнай, бұлттылық, бұлт көлеңкесі, су, урбандалған аумақ, топырақ, өсімдік жамылғысы, мұнай төгінділеріне спектрлік тұрғыдан ұқсас нысандар класы (егіздер), жол және фон. «Көлеңке» класы «мұнай» класының ықтимал спектрлік антагонисі ретінде осы кезеңде арнайы бөлініп алынды, өйткені екі нысан да кескінде қараңғы тонмен көрінеді және оларды ажырату мұнай ластануын дұрыс анықтау үшін маңызды. Бұл ретте көлеңкелер тек бұлт көлеңкесінен ғана емес, сонымен қатар ғимараттар, өндірістік құрылыстар мен басқа да биік нысандардың түсіруінен де пайда болуы мүмкін, сондықтан класс осындай жағдайлардың барлығын қамту үшін жалпылама сипатта белгіленген. «Бұлттылық» класы, керісінше, ашық реңкімен ерекшеленеді және мұнаймен спектрлік тұрғыдан шатаспайды; ол жеке мозаикаларда кездесетін болмашы фрагменттерді жіктеу схемасының толықтығы үшін дұрыс белгілеу мақсатында сақталды.
- Өсімдік жамылғысы индексі (NDVI) [12] есептеу, өсімдік жамылғысы мен су нысандары класын бөліп алу мақсатында жасалды.
- Векторлық деректерге түрлендіру. Нәтижелерді нақтылау және түзету мақсатында жіктеу растрлары векторлық форматқа түрлендірілді.
- Алдын ала жіктеуді талдау және түзету ArcGIS бағдарламасында жүргізілді. Мұнаймен ластанған аймақтардың векторланған деректерін қолмен нақтылауға ерекше назар аударылды. Олар алдыңғы зерттеулер деректері (ROSID), экологиялық

мониторингтің тарихи деректері және спутниктік кескіндерді сараптамалық дешифрлеу негізінде түзетілді.

- Аннотацияланған кескіндерді қалыптастыру үшін түзетілген векторлық деректерді GeoTIFF форматына түрлендіру.
- PlanetScore түсірілімдері негізінде ұшарналы синтезделген кескіндерді қалыптастыру мұнай қабыршақтары мен мұнаймен ластанған топырақтың максималды визуалды және тоналды контрастын қамтамасыз ететін спектрлік арналардың оңтайлы үйлесімі негізінде жүзеге асырылды.
- Оқыту, валидациялау және тестілеу жиындарына бөлу. Кеңістіктік деректердің өтуін болдырмау үшін бастапқы толық мөлшерлі мозаикалар (кескіндер) патчтарға кесілгенге дейін географиялық/кеңістіктік тұрғыдан оқыту, валидациялау және тестілеу жиындарына бөлінді. Бұл бір аумақтың көршілес немесе қабаттасатын фрагменттерінің әртүрлі жиындарға түсу қаупін толығымен жойды.
- Деректер жиынтығын ығыстыру арқылы фрагменттеу. Түзетілген растрлық маскалар мен оларға сәйкес түсірілімдер 512×512 пиксель өлшемді патчтарға 256 пиксель ығысумен фрагменттелді.



Сурет 1. Жоғары ажыратымдылықтағы спутниктік түсірілімдерді өңдеу тізбегі

Қалыптастырылған ROSID-HR деректер жинағы семантикалық сегментация модельдерін оқыту және бағалау үшін негіз ретінде пайдаланылды. Құрлықтағы мұнай төгінділерін автоматты картографиялау есебі ластанған учаскелерді дәл идентификациялап, сегменттей алатын кескіндерді өңдеу әдістерін қолдануды талап етеді. Осы зерттеуде семантикалық сегментация жүргізу үшін екі түрлі нейрожелілік архитектура таңдалды; бұл классикалық конволюциялық және трансформерлік тәсілдердің тиімділігіне ортақ оқыту деректерінде салыстырмалы талдау жүргізуге мүмкіндік берді.

Конволюциялық нейрондық желілер (CNN) кескіндерден қарапайым жиектер мен текстуралардан бастап күрделі нысандық сипаттамаларға дейінгі кеңістіктік белгілерді автоматты түрде үйрену қабілетінің арқасында компьютерлік көру саласында кеңінен қолданылады [13]. Математикалық тұрғыдан I кескінінің K ядросымен дискретті конволюциясы (1) теңдеуімен анықталады:

$$S(i, j) = (I \cdot K)(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (1)$$

мұндағы $S(i, j)$ - шығыс белгілер картасы (feature map), ал m мен n - конволюциялық ядроның кеңістіктік индекстері.

Кескіндерді жіктеуде бүкіл кескін үшін бір класс анықталса, семантикалық сегментацияда әрбір пиксель жеке жіктеледі. Бұл шығыс қабатында кеңістіктік ақпараттың сақталуын талап етеді, сондықтан толық байланысқан қабаттардың орнына 1×1 конволюциясы қолданылады.

DeepLabv3+ архитектурасы [14] параметрлер санын көбейтпестен нейронның қабылдау өрісін кеңейтуге мүмкіндік беретін кеңейтілген (атрозды) конволюцияларға негізделеді. Атрозды конволюцияның шығыс сигналы u , сүзгі w арқылы өңделген кезде әрбір i пикселі үшін (2) теңдеуімен сипатталады:

$$y[i] = \sum_{k=1}^K x[i + r \cdot k] w[k] \quad (2)$$

мұндағы x - кіріс сигналы, $w[k]$ - сүзгі коэффициенті, r - сүзгі элементтері арасындағы арақашықтықты анықтайтын дилатация коэффициенті. Көпмасштабты белгілерді бөліп алу үшін модель атрозды кеңістіктік пирамидалық пулинг модулін (Atrous Spatial Pyramid Pooling, ASPP) пайдаланады. ASPP модулінде әртүрлі r мәндерімен бірнеше параллель конволюция орындалады, олардың нәтижелері кейіннен біріктіріліп, ортақ белгілер көрінісін қалыптастырады.

Сегментация шекараларының жоғары дәлдігі энкодер-декодер архитектурасы арқылы қамтамасыз етіледі: энкодер кескінің семантикалық ерекшеліктерін бөліп алса, декодер жоғалған кеңістіктік ақпаратты қалпына келтіреді. Сонымен қатар, DeepLabv3+ архитектурасында стандартты конволюциялық қабаттардың орнына тереңдік бойынша бөлінетін конволюциялар (depthwise separable convolutions) қолданылады. Бұл тәсіл мұнаймен ластанған учаскелерді анықтау дәлдігін сақтай отырып, модельдің есептеу күрделілігі мен параметрлер санын едәуір азайтуға мүмкіндік береді.

Mask2Former - әмбебап сегментация тапсырмаларын орындауға арналған заманауи мета-архитектура [15]. Әдіс трансформер негізіндегі декодер арқылы маскарларды жіктеу принципіне негізделген. Оның негізгі компоненті - назар аудару аймағын нақты сегменттермен шектейтін бүркемеленген назар механизмі (3):

$$X_l = \text{Softmax}(M_{l-1} + Q_l K_l^T) V_l + X_{l-1} \quad (3)$$

мұндағы X_l - l қабатының кіріс белгілері, l , Q_l , K_l , V_l - сәйкесінше сұраулар, кілттер және мәндер матрицалары.

(3) теңдеудегі M_{l-1} маскасы назар аудару матрицасын басқарып, назардың тек болжанған маска ішіндегі белгілерге бағытталуын қамтамасыз етеді (4):

$$M_{l-1}(x, y) = \begin{cases} 0, & \text{if } M_{l-1}(x, y) = 1 \\ -\infty, & \text{otherwise} \end{cases} \quad (4)$$

Мұндағы $m_{l-1} \in \{0, 1\}$ декодердің ағымдағы қабатындағы белгілер карталарының масштабна келтірілген мақсатты класстың екілік маскасы.

Эксперименттерді жүргізу шарттары. Жұмыста PyTorch ашық бастапқы бағдарламалық кітапханасы қолданылды [16]. Барлық есептеу эксперименттері NVIDIA Quadro RTX 5000 графикалық процессорларында жүргізілді. Кіріс кескіндер 512×512 пиксель өлшеміне келтірілді, әрі әрбір арна бойынша орташа мәндері [123.675; 116.28; 103.53] және стандартты ауытқулары [58.395; 57.12; 57.375] болатындай нормаланды. Бұл алдын ала өңдеу қадамы оқыту процесінің жинақталуын жеделдетуге және модельдің тұрақты оқытылуын қамтамасыз етуге бағытталған.

Модельдердің тұрақтылығы мен жалпылау қабілетін арттыру үшін деректерді аугментациялау әдістері қолданылды: кескіндерді 50...200% диапазонында кездейсоқ масштабтау; фондық кластардың басымдығын азайту үшін фрагменттерді ең үлкен коэффициенті 0.75 болатын кездейсоқ кесіп алу (random cropping); әртүрлі

жарықтандыру және сыртқы орта жағдайларына ұқсас кескін алу үшін көлденең шағылыстыру, сондай-ақ жарықтық пен түсті өзгерту.

1-кестеде әр класс үшін пиксельдер саны көрсетілген. «Мұнай» класы элементтердің жалпы санының 2.45%-ын құрайды (фон класын есепке алмағанда). Деректер жинағында кластардың елеулі теңгерімсіздігі байқалады: «мұнай» класында 70 682 248 пиксель бар, ал «топырақ» класында 1 218 895 998 пиксель бар (1-кесте).

Кесте 1

ROSID-HR деректер жинағындағы әрбір класс пиксельдерінің саны

Реті	Класс атауы	Пиксельдер саны
1	Мұнай	70 682 248
2	Бұлттылық	435 260
3	Көлеңке	730 402
4	Су	2 046 640
5	Урбандалған аумақ	22 534 446
6	Топырақ	1 218 895 998
7	Өсімдік жамылғысы	7 525 947
8	Егіздер	412 174
9	Жол	5 188 482
10	Фон	1 554 964 723

Бұл теңгерімсіздік деректердің табиғи біркелкі еместігімен түсіндіріледі, өйткені ластанған учаскелердің ауданы фондық топырақ жамылғысымен салыстырғанда айтарлықтай аз. Деректерді жасанды түрде теңгерімдеуден бас тарту деректердің шынайы таралуын сақтау және модельдің жалпылау қабілетін төмендетпеу мақсатында жүзеге асырылды. Қазіргі теңгерімсіздік өңірдің нақты жағдайын дәл бейнелейді.

Оқыту конфигурациясы. Батч өлшемі 4-ке тең етіп белгіленді. Қайта оқыту әсерлерінің алдын алу үшін InfiniteSampler құралы қолданылды, ол деректердің үздіксіз кездейсоқ араластырылуын қамтамасыз етті. Алдын ала өңдеу процесі тікелей DataLoader деректер жүктеушісіне біріктірілді, бұл есептеу тізбегіндегі кідірістерді барынша азайтуға мүмкіндік берді.

Модельдерді оптимизациялау Adam алгоритмі негізінде, бастапқы оқыту жылдамдығы 0.001 мәнінде жүзеге асырылды. Шығын функциясы ретінде кластар теңгерімсіздігіне төзімді кросс энтропия қолданылды. Модельдердің архитектуралық ерекшеліктеріне байланысты итерациялар саны жекешелендірілді: конволюциялық DeepLabv3+ моделі үшін 40 000 итерация белгіленді, бұл оның индуктивті ауытқуының (inductive bias) жоғары болуына байланысты толық конвергенцияға жетуіне жеткілікті болды. Ал трансформерлік Mask2Former моделі үшін итерация саны 60 000-ға дейін арттырылды, бұл оның назар аудару механизмінің (attention mechanism) күрделілігімен және маскаларды венгерлік сәйкестендіру (bipartite matching) процедурасының баяу тұрақтануымен түсіндіріледі. Осылайша, екі модель де өзінің максималды потенциалды мүмкіндігіне жеткен сәтте өзара салыстырылды.

Валидация және тестілеу конфигурациясы. Объективті бағалауды қамтамасыз ету үшін батч өлшемі 1 мәніне тең етіп белгіленді. Кескіндер геометриялық бұрмаланусыз 512×512 пиксель өлшеміне дейін масштабталды. DefaultSampler араластырусыз қолданылды, бұл нәтижелердің қайталанымдылығын қамтамасыз етті.

Бағалау метрикалары. Кластардың айқын теңгерімсіздігі жағдайында сегментация сапасын сандық талдау үшін компьютерлік көрудің стандартты метрикалар жиынтығы пайдаланылды [17...19]:

- IoU (қиылысудың бірігуге қатынасы) болжанған маска мен эталондық белгілеу арасындағы сәйкестік өлшемі болып табылады және олардың кеңістіктік қабаттасу дәрежесін көрсетеді.
- Accuracy (жалпы дәлдік) кескіндегі пиксельдердің жалпы санынан дұрыс жіктелген пиксельдердің үлесі.
- Precision (нақтылық) модельдің фондық немесе ұқсас нысандарды (мысалы, көлеңкелер немесе ылғалды учаскелер) қате жатқызу жиілігін төмендету қабілетін сипаттайды.
- Recall (толықтық) модельдің барлық нақты ластану учаскелерін өткізіп алмай анықтау қабілетінің сипаттамасы.
- F1-өлшемі Precision және Recall көрсеткіштерінің гармониялық орташа мәні ретінде жалған позитивтер мен жалған негативтер арасындағы теңгерімді бағалайтын метрика.

3. НӘТИЖЕЛЕР ЖӘНЕ ТАЛҚЫЛАУ

Арналардың оңтайлы конфигурациясын таңдау. Зерттеудің негізгі кезеңдерінің бірі – мұнай ластануларын анықтау үшін PlanetScope түсірілімдерінің спектрлік арналарының ең тиімді үйлесімін айқындау болды. Өртүрлі арна композиттері сыналып, мынадай нәтижелер алынды:

Композит 8-4-3 (NIR, Green, Green I). Бұл үйлесім өсімдік жамылғысын мониторингілеу үшін стандартты түрде қолданылғанымен, құрлықтағы мұнайды сегменттеу есебінде өте төмен сезімталдық көрсетті. Метрикалардың мәндері (IoU: 2.09%, Recall: 2.17%) осы арналар жиынтығының мұнай мен топырақ арасында жеткілікті контраст бермейтінін және мақсатты нысандардың жаппай өткізіп алынуына әкелетінін көрсетеді.

Композит 8-7-5 (NIR, Red-Edge, Yellow). Бұл комбинация жоғары нақтылық көрсетті (Precision: 68.1%), алайда төмен толықтыққа ие болды, яғни модель мұнаймен ластанған аумақтардың едәуір бөлігін елемейді.

Композит 6-4-8 (Red, Green, NIR). Бұл арналар үйлесімі негізгі көрсеткіштердің жақсаруына әкелді әрі бастапқыда ең оңтайлы ретінде қарастырылды. Көрінетін диапазон арналары (Red, Green) мен жақын инфрақызыл (NIR) арнасының бірлескен қолданылуы кластарды спектрлік тұрғыдан тиімді ажыратуды қамтамасыз етті. NIR арнасы ылғал ұстайтын құрылымдар мен мұнай өнімдерін бөліп алу үшін маңызды болып шықты, ал Red және Green арналары қоршаған топырақ пен жол желісімен қажетті контраст жасады. Бұл композит дәлдік (62.28%) пен толықтық (34.09%) арасында жақсы тепе-теңдікке қол жеткізуге мүмкіндік берді әрі «мұнай» класы үшін IoU мәнін (28.26%) көрсетті. Осы композит пен алынған бағалаулар қорытынды конфигурацияны іздеудегі маңызды кезең болды.

Композит 2-6-8 (Blue, Red, NIR). Көк арнаны (Blue) қызыл (Red) және жақын инфрақызыл (NIR) арналармен үйлестіру мұнаймен ластанған аумақтарды жер беті мен табиғи көлеңкелерден тиімді ажыратуды қамтамасыз етті. Бұл композит «мұнай» класы үшін ең жоғары көрсеткіштерге қол жеткізуге мүмкіндік берді. Нақтылық (Precision) 63.29% болды, толықтық (Recall) 46.13%-ке дейін өсті, ал қорытынды IoU мәні 36.4%-бен ең жоғары деңгейге жетті. Осылайша, бұл композит модельдерді оқыту және қорытынды валидациялау үшін оңтайлы ретінде таңдалды.

DeepLabv3+ архитектурасының нәтижелері. ASPP механизмін пайдалана отырып көпмасштабты контекстті қамтитын DeepLabv3+ архитектурасының тиімділігі валидация және финалдық тестілеу кезеңдерінде бағаланды. «Мұнай» класы үшін валидациядағы IoU мәні 30.08% болды, бұл ретте дәлдік (Precision: 44.19%) мен толықтық (Recall: 48.5%) арасындағы тепе-теңдік жалған оң дабылдардың орташа үлесін көрсетеді (2-кестені қараңыз).

Кесте 2*DeepLabv3+ архитектурасының валидациялық деректердегі метрикалары*

Класс	IoU (%)	F1-өлшемі (%)	Precision (%)	Recall (%)
Мұнай	30.08	46.25	44.19	48.50
Бұлттылық	0.00	nan	nan	0.00
Көлеңке	0.00	nan	nan	0.00
Су	0.00	nan	nan	0.00
Урбандалған аумақ	0.00	nan	nan	0.00
Топырақ	96.61	98.28	96.88	99.72
Өсімдік жамылғысы	0.00	nan	nan	0.00
Егіздер	0.00	nan	nan	0.00
Жол	0.00	nan	nan	0.00
Фон	99.48	99.74	99.71	99.77

«Топырақ» (IoU: 96.61%) және «фон» (IoU: 99.48%) кластары үшін жоғары дәлдік модельдің фондық беттерді жіктеудегі тұрақтылығын растайды. Алайда «урбандалған аумақ», «жол» және «өсімдік жамылғысы» кластары үшін нөлге ұмтылатын тым төмен метрика мәндері архитектураның шағын өлшемді немесе спектрлік тұрғыдан күрделі нысандардың белгілерін дұрыс бөліп ала алмайтынын көрсетеді. Бұл DeepLabv3+ конволюциялық негізінің айқын кластар теңгерімсіздігі жағдайында сирек кездесетін класстарды басым «топырақ» класы есебінен басып тастау (class collapse / dominance) тенденциясына бейім екенін көрсетеді.

Тестілік деректер жиынына көшкен кезде сапа көрсеткіштерінде айқын өзгеріс байқалады. Нәтижелерге сәйкес (3-кестені қараңыз), «мұнай» класы үшін толықтық (Recall) көрсеткіші 58.73%-ке дейін өсті, бұл модельдің ластанудың үлкен ауданын анықтай алу қабілетін көрсетеді.

Кесте 3*DeepLabv3+ архитектурасының тестілік деректердегі метрикалары*

Класс	IoU (%)	F1-өлшемі (%)	Precision (%)	Recall (%)
Мұнай	21.63	35.57	25.51	58.73
Бұлттылық	nan	nan	nan	nan
Көлеңке	nan	nan	nan	nan
Су	0.00	nan	nan	0.00
Урбандалған аумақ	0.00	nan	nan	0.00
Топырақ	96.89	98.42	97.16	99.71
Өсімдік жамылғысы	0.00	nan	nan	0.00
Егіздер	0.00	nan	nan	0.00
Жол	0.00	nan	nan	0.00
Фон	99.53	99.76	99.83	99.7

Екінші жағынан, бұл дәлдіктің (Precision) 25.51%-ке дейін күрт төмендеуімен қатар жүріп, IoU көрсеткішінің 21.63%-ға дейін азаюына әкелді. Мұндай алшақтық, жол желісін тану сапасының төмендігімен бірге, модельдің спектрлік шуылдарға жоғары сезімталдығы туралы болжамды растайды. Басқаша айтқанда, жол элементтері мен көлеңкелер кате түрде мұнай дақтары ретінде жіктеледі.

Mask2Former архитектурасының нәтижелері. Әмбебап маска сегментациясы механизмі мен назар (attention) стратегияларын пайдаланатын Mask2Former архитектурасын қолдану нысандарды анықтау дәлдігінің айтарлықтай артуына әкелді.

Валидация кезеңінде (4-кестені қараңыз) Mask2Former моделі DeepLabv3+-пен салыстырғанда жақсы нәтижелер көрсетті. IoU мәні «мұнай» класы үшін 64.6%-ке дейін өсті. Дәлдік (Precision: 73.42%) пен толықтықтың (Recall: 84.33%) жоғары көрсеткіштері мұнай ластануларының белгілерін бөліп алу үшін пайдаланудың тиімділігін растайды.

Кесте 4

Mask2Former архитектурасының валидациялық деректердегі метрикалары

Класс	IoU (%)	F1-өлшемі (%)	Precision (%)	Recall (%)
Мұнай	64.6	78.49	73.42	84.33
Бұлттылық	1.64	3.23	81.96	1.65
Көлеңке	39.69	56.82	48.68	68.25
Су	50.98	67.54	65.25	69.99
Урбандалған аумақ	84.85	91.81	92.03	91.59
Топырақ	98.5	99.24	99.1	99.39
Өсімдік жамылғысы	23.68	38.29	53.97	29.67
Егіздер	4.68	8.94	12.17	7.07
Жол	38.11	55.18	58.76	52.02
Фон	99.91	99.95	99.96	99.95

DeepLabv3+-пен салыстырғанда Mask2Former архитектурасы кластарды сегменттеуде жоғары ажырату қабілетін көрсетті. «Урбандалған аумақ» (IoU: 84.85%) және «су» (IoU: 50.98 %) кластарын сәтті анықтау трансформерлік архитектураның фондық шуылдың әсерін басу қабілетін көрсетеді. «Жол» класы сегментациясының жақсаруы маңызды жетістік болды (IoU: 38.11%), өйткені модель жол төсемі мен мұнаймен ластанған аумақтарды сәтті ажырата бастады, бұл бұрын жалған дабылдардың себебі болатын.

Тестілік деректер жиынындағы нәтижелер (5-кестені қараңыз) архитектураның тұрақтылығын растады: «мұнай» класы үшін IoU көрсеткіші 69.73%-ке дейін өсті, ал толықтық (Recall) 93.78%-ке жетті. Дәлдік (Precision: 73.12%) мәнінің тұрақтылығы модельдің фрагменттелген және төмен контрастты мұнаймен ластанған аумақтарды сенімді түрде анықтай алатынын айғақтайды, бұл жоғары Recall көрсеткішімен қатар байқалады. «Топырақ» (IoU: 98.95%) және «урбандалған аумақ» (IoU: 87.18%) кластары бойынша тұрақты жоғары нәтижелер модельдің әртүрлі ландшафт сценарийлерінде сенімді жұмыс істейтінін көрсетеді.

Кесте 5


Mask2Former архитектурасының тестілік деректердегі метрикалары

Класс	IoU (%)	F1-өлшемі (%)	Precision (%)	Recall (%)
Мұнай	69.73	82.17	73.12	93.78
Бұлттылық	0.00	nan	0.00	nan
Көлеңке	0.00	nan	0.00	nan
Су	41.77	58.92	80.53	46.46
Урбандалған аумақ	87.18	93.15	93.36	92.94
Топырақ	98.95	99.47	99.36	99.58
Өсімдік жамылғысы	12.46	22.16	52.64	14.03
Егіздер	3.09	5.99	11.19	4.09
Жол	38.07	55.14	60.93	50.36
Фон	99.95	99.97	99.97	99.98


Сегментация нәтижелерін визуалды салыстыру. Planet спутниктік деректері бойынша сегментация нәтижелерінің 2020 жылғы маусым мен 2024 жылғы қыркүйек айларындағы визуалды салыстыруы 2 және 3-суреттерде келтірілген.

Бастапқы жазғы мозаикада (2а-сурет) мұнай ластануына сәйкес келетін, «мұнай көлі» деп аталатын ірі қою түсті аймақ ерекшеленеді. Бұдан басқа, 2а-суретте су, инфрақұрылым элементтері және топырақ аймақтары да айқын көрінеді. 2б-суретте эталондық белгілеу ретінде қолданылған және негізгі сегментация кластарын қамтитын аннотацияланған кескін көрсетілген. Конволюциялық DeepLabv3+ моделі мұнай ластануының негізгі аймағын тұтастай дұрыс бөліп көрсетеді (2в-сурет), алайда жекелеген кластарды қате жіктеу жағдайлары байқалады. Нақты айтқанда, жалған мұнай белгілері бар, ал «урбандалған аумақ» және «су» кластарымен сәйкес келетін объектілер анықталмаған. Mask2Former моделі DeepLabv3+-пен салыстырғанда мұнай ластануы шекараларын дәлірек сәйкестендіреді, сондай-ақ урбандалған аймақ, су беттерін және жол желісін дұрысырақ ажыратады.

Дешифрлеудің ұқсас нәтижелері 2024 жылға арналған деректерде де тіркелді (3-сурет). Осы екі суретті визуалды талдау екі модельдің де мұнай ластануының негізгі аймақтарын анықтай алатынын көрсетеді. Алайда DeepLabv3+ моделі бойынша сегментация нәтижелерін егжей-тегжейлі қарастыру (2в-сурет, 3в-сурет) «мұнай» класы контурларының бұлыңғырлығын және мұнай аймағының өз ішіндегі «фон» класы артефактілерінің болуын анықтайды. Ал Mask2Former моделі (2г-сурет, 3г-сурет) кластарды анағұрлым айқын әрі нақты шекаралармен сегментациялайды. Бұған қоса, кескіннің ғаламдық контекстін ескеру қабілетінің арқасында Mask2Former архитектурасы ластану аймақтарын тұтас нысандар ретінде қабылдайды, бұл мұнай ластануын өсімдік жамылғысы, инфрақұрылым элементтері және көлеңкелер сияқты спектрлік тұрғыдан ұқсас кластардан барынша жақсы ажыратуға мүмкіндік береді әрі жалған детекциялар санын барынша азайтады.



Сурет 2. 2020 жылғы маусымдағы сегментация нәтижелерін салыстыру: а) бастапқы кескін, б) аннотацияланған кескін, в) DeepLabv3+ моделі бойынша сегментация, г) Mask2Former моделі бойынша сегментация



Сурет 3. 2024 жылғы қыркүйектегі сегментация нәтижелерін салыстыру: а) бастапқы кескін, б) аннотацияланған кескін, в) DeepLabv3+ моделі бойынша сегментация, г) Mask2Former моделі бойынша сегментация

Талқылау. Жүргізілген зерттеуде алынған нәтижелер трансформерлік Mask2Former архитектурасының классикалық конволюциялық DeepLabv3+ желісінен сандық метрикалар бойынша да, нысан шекараларын бөліп алу сапасы бойынша да тұрақты түрде басым екенін растады. «Мұнай» мақсатты класы үшін тестілеуде Mask2Former моделі 69,73%-ке тең IoU көрсетті, ал DeepLabv3+ үшін бұл көрсеткіш небәрі 21,63% болды. Мұндай айырмашылық практикалық тұрғыдан маңызды, өйткені анықтау дәлдігі кейінгі рекультивацияның көлемі мен құнын есептеуге тікелей әсер етеді. Сонымен қатар, бұл зерттеуде байқалған трансформерлік тәсілдердің мақсатты кластарды сегментациялаудағы жоғары тиімділігі Чэн және әріптестерінің [14] компьютерлік көру есептеріндегі трансформер архитектураларының артықшылықтары туралы тұжырымдарымен сәйкес келеді.

Mask2Former архитектурасының қосымша артықшылығы спектрлік тұрғыдан ұқсас кластарға - жолдарға, көлеңкелерге және урбандалған нысандарға - жоғары төзімділігі болып табылады, бұл DeepLabv3+ моделінде жалған дабылдардың негізгі себебі болып табылды. Асфальт, ылғалды топырақ және ғимараттардың көлеңкелері жекелеген арналарда ұқсас жарықтық мәндеріне ие болуы мүмкін, сондықтан DeepLabv3+ моделі жағдайындағыдай жергілікті спектрлік контрастылыққа сүйенсе, қателік ықтималдығы күрт артады. Mask2Former-дегі ғаламдық контекстті пайдалану нысандардың пішінін, олардың қоршауын кеңістіктік құрылымын ескеруге мүмкіндік береді. Осылайша, Mask2Former моделінің барлық кластар бойынша жиынтық көрсеткіштердегі басымдығы кездейсоқ емес: ол дәл осы ең күрделі және практикалық маңызы зор кіші тапсырманы - «мұнай» класын спектрлік тұрғыдан жақын «топырақ» және «көлеңке» кластарынан ажыратуды - едәуір жақсы шешуінен туындайды.

Спектрлік сипаттамаларды талдау сегментация тиімділігінің PlanetScope арналарының үйлесіміне тікелей тәуелді екенін көрсетті. Атап айтқанда, эксперименттер Blue, Red, NIR (2, 6, 8 арналары) үйлесімінің ең жақсы нәтиже беретінін көрсетті. Бұл, бәлкім, көк арнаның топырақ пен мұнай арасындағы айырмашылыққа сезімталдығымен, сондай-ақ қызыл және жақын инфрақызыл арналардың органикалық заттардың болуына

реакциясымен байланысты түсіндіріледі. Олардың үйлесімі анағұрлым тұрақты және дискриминативті спектрлік белгілерді қалыптастырады.

Жұмыстың практикалық құндылығы мұнай кәсіпшілігі аумақтарын жүйелі бақылау мүмкіндігінде. Бұл әсіресе қол жеткізуі қиын немесе кең байтақ аудандар үшін өзекті.

Сонымен бірге, ұсынылған зерттеудің кейбір шектеулері бар. Біріншіден, модель белгілі бір кен орындарының деректерінде оқытылды, сондықтан оны өзге климаттық және ландшафттық жағдайдағы аумақтарға қолдану қосымша валидацияны талап етеді. Екіншіден, модель сапасы оқыту жинағын қолмен белгілеу дәлдігіне қатты тәуелді, бұл сараптамалық дешифрлеу сатысының маңыздылығын арттырады.

Алдағы уақытта оқыту жиынын әртүрлі мұнай кен орындарының деректері есебінен кеңейту, сондай-ақ төрттен астам спектрлік арнаны тікелей пайдаланатын архитектураларды әзірлеу жоспарланып отыр. Бұл мұнаймен ластанған аумақтардың тозу және кейіннен қалпына келу процестерін егжей-тегжейлі қадағалауға мүмкіндік береді.

4. ҚОРЫТЫНДЫ

Осы зерттеу шеңберінде PlanetScope жоғары ажыратымдылықтағы спутниктік түсірілімдері негізінде мұнаймен ластанған аумақтарды анықтауға арналған терең оқыту архитектураларына салыстырмалы талдау жүргізілді.

Зерттеудің маңызды кезеңі бастапқы түсірілімдердің спектрлік арналарының ең оңтайлы конфигурациясын таңдау болды. Эксперимент жүзінде Blue, Red, NIR композитін (2-6-8 арналары) пайдалану топырақ бетіндегі мұнай өнімдерін басқа техногендік нысандар мен көлеңкелерден жақсы бөліп алуды қамтамасыз ететіні дәлелденді, бұл басқа арна үйлесімдерімен салыстырғанда анықтау дәлдігін арттыруға мүмкіндік берді.

Ұсынылған тәсілдің тиімділігін бағалау үшін екі заманауи терең оқыту архитектурасы сыналды: классикалық конволюциялық DeepLabv3+ моделі мен трансформерлік Mask2Former архитектурасы. Салыстырмалы талдау нәтижелері Mask2Former моделінің артықшылығын анықтады. Ол қорытынды тестілеу кезеңінде «мұнай» мақсатты класы үшін IoU мәнінің 69.73%-ке жетуін қамтамасыз етті, бұл DeepLabv3+ моделінің көрсеткішінен (21.63%) үш еседен астам жоғары. Анықтаудың жоғары толықтығы (Recall 93.78%) мен басым «топырақ» класына төзімділігі трансформерлік архитектура механизмдерінің морфологиясы күрделі нысандарды идентификациялау есептеріндегі артықшылығын растайды. Басқаша айтқанда, трансформерлерге негізделген архитектура шекаралары күрделі әрі масштабтары әртүрлі нысандарды сегменттеуді жақсырақ атқарады.

Mask2Former моделінің сегментация дәлдігі мен тұрақтылығы оны мұнаймен ластанған аумақтарды экологиялық мониторингілеу және жер бетін мұнайдан тазарту жөніндегі рекультивациялық жұмыстарды бақылау кезінде қолдануға жарамды етеді. Сонымен қатар спектрлік арналардың ең оңтайлы үйлесімін пайдалану модельдің күрделі ландшафттық жағдайларға төзімділігін арттыруға және «мұнай төгінділеріне спектрлік тұрғыдан ұқсас нысандар(Егіздер)» класын жіктеу қателерін барынша азайтуға мүмкіндік берді, бұл мұнаймен ластанған аумақтарды бақылау үшін дәл осы спектрлік конфигурацияны пайдаланудың орындылығын растайды.

Алдағы зерттеулер төрттен астам спектрлік арнасы бар ғарыштық көпарналы кескіндерді тануға арналған жасанды нейрондық желі моделінің жаңа архитектурасын әзірлеуге, әрбір арнаның өзіндік сипаттамалары мен ерекшеліктерін ескере отырып, тану дәлдігін арттыру мақсатында бағытталатын болады.

ДЕРЕКТЕРДІҢ ҚОЛ ЖЕТІМДІЛІГІ

Зерттеуде пайдаланылған деректер авторлар жүргізген эксперименттік зерттеулер нәтижесінде алынған. Зерттеу нәтижелерін растайтын деректер тиісті авторға негізді сұрау салу арқылы қолжетімді.

АВТОРЛАРДЫҢ ҚОСҚАН ҮЛЕСІ

Тұжырымдаманы әзірлеу – Ғ.С.Ә., Д.Б.Н.; Әдіснама – Ғ.С.Ә., Л.А.Б., С.М.Н.; Деректерді дайындау – Т.В.Д.; Ресурстар – Т.В.Д., С.М.Н.; Формалды талдау – Д.Б.Н.; Валидация – Л.А.Б.; Визуализация – Т.В.Д.; Қолжазбаның бастапқы нұсқасын дайындау – Л.А.Б.; Қолжазбаны жазу, рецензиялау және редакциялау – Ғ.С.Ә.

ҚАРЖЫЛАНДЫРУ

Бұл зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігі Ғылым комитетінің қаржыландыруымен жүргізілді (ЖТН AP26102621 «Жоғары ажыратымдылықтағы қашықтан зондау деректері бойынша мұнаймен ластанған аумақтарды тануға арналған жасанды нейрондық желі моделін әзірлеу»).

ӘДЕБИЕТТЕР ТІЗІМІ

1. Андерсон Р.К., Мукатанов А.Х., Бойко Т.Ф. Экологические последствия загрязнения почв нефтью // Экология. 1980. № 6. С. 21–25.
2. Досбергенов С.Н. Экологические проблемы нефтезагрязненных почв в районах добычи нефти Западного Казахстана и пути их решения // Гидрометеорология и экология. 2010. № 3. С. 111–122.
3. Национальный доклад о состоянии окружающей среды и об использовании природных ресурсов Республики Казахстан за 2022 год [Электронный ресурс]. Астана, 2023. С. 71. URL: <https://ecogofond.kz/wp-content/uploads/2023/12/NDSOS-2022-RUS-gotov1-1.pdf> (дата обращения: 29.09.2025).
4. Lassalle G., Fabre S., Credo A., Dubucq D., Elger A. Monitoring oil contamination in vegetated areas with optical remote sensing: a comprehensive review // Journal of Hazardous Materials. 2020. Vol. 393. Art. 122427. DOI: 10.1016/j.jhazmat.2020.122427.
5. Abbas D.U.K., George L.E. The detection of oil spill onshore using the thermal band of Landsat-8 // TELKOMNIKA (Telecommunication Computing Electronics and Control). 2022. Vol. 20. No. 2. P. 383–391. DOI: 10.12928/telkomnika.v20i2.22462.
6. Ozgis M.S., Kaduk J.D., Jarvis C.H. Mapping terrestrial oil spill impact using machine learning random forest and Landsat-8 OLI imagery // Environmental Science and Pollution Research. 2019. Vol. 26. P. 3621–3635. DOI: 10.1007/s11356-018-3824-y.
7. Kaplan G., Aydinli H., Pietrelli A., Mieveville F., Ferrara V. Oil-contaminated soil modeling and remediation monitoring in arid areas using remote sensing // Remote Sensing. 2022. Vol. 14. No. 10. Art. 2500. DOI: 10.3390/rs14102500.
8. Zhu X.X., Tuia D., Mou L., Xia G.S., Zhang L., Xu F., Fraundorfer F. Deep learning in remote sensing: a comprehensive review and list of resources // IEEE Geoscience and Remote Sensing Magazine. 2017. Vol. 5. P. 8–36. DOI: 10.1109/MGRS.2017.2762307.
9. Zheng A., Casari A. Feature engineering for machine learning: principles and techniques for data scientists. Sebastopol: O'Reilly Media, 2018. 218 c.
10. Bengio Y., Courville A., Vincent P. Representation learning: a review and new perspectives // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2013. Vol. 35. No. 8. P. 1798–1828. DOI: 10.1109/TPAMI.2013.50.
11. Nurseitov D.B., Abdimanap G., Abdallah A., Sagatdinova G., Balakay L., Dedova T., Rametov N., Alimova A. ROSID: Remote sensing satellite data for oil spill detection on land // Engineering Sciences. 2024. Vol. 32. Art. 1348. DOI: 10.30919/es1348.
12. EOS Data Analytics. NDVI: Нормализованный разностный вегетационный индекс [Электронный ресурс]. URL: <https://eos.com/blog/normalized-difference-vegetation-index-or-ndvi/> (дата обращения: 29.09.2025).
13. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // Communications of the ACM. 2017. Vol. 60. No. 6. P. 84–90. DOI: 10.1145/3065386.
14. Chen L.-C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-decoder with atrous separable convolution for semantic image segmentation // Proceedings of the European Conference on Computer Vision (ECCV). 2018. P. 801–818. DOI: 10.1007/978-3-030-01234-2_49.
15. Cheng B., Misra I., Schwing A.G., Kirillov A., Girdhar R. Masked-attention mask transformer for universal image segmentation // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 1290–1299. DOI: 10.1109/CVPR52688.2022.00135.
16. Rouso R., Katz N., Sharon G., Glizerin Y., Kosman E., Shuster A. Automatic recognition of oil spills using neural networks and classic image processing // Water. 2022. Vol. 14. No. 7. Art. 1127. DOI: 10.3390/w14071127.
17. Everingham M., Van Gool L., Williams C.K.I., Winn J., Zisserman A. The Pascal visual object classes (VOC) challenge // International Journal of Computer Vision. 2010. Vol. 88. P. 303–338. DOI: 10.1007/s11263-009-0275-4.
18. Hossin M., Sulaiman M.N. A review on evaluation metrics for data classification evaluations // International Journal of Data Mining & Knowledge Management Process. 2015. Vol. 5. No. 2. P. 1–11. DOI: 10.5121/ijdkp.2015.5201.
19. Rahman M.A., Wang Y. Optimizing Intersection-over-Union in deep neural networks for image segmentation // Proceedings of the International Symposium on Visual Computing (ISVC). 2016. P. 234–244. DOI: 10.1007/978-3-319-50307-3_11.

REFERENCES

1. Anderson, R. K., Mukatanov, A. Kh., & Boyko, T. F. (1980). Ekologicheskie posledstviya zagryazneniya pochv neftyu [Environmental consequences of oil contamination of soils]. Ekologiya, (6), 21–25. (in Russian).
2. Dosbergenov, S. N. (2010). Ekologicheskie problemy neftezagryaznennykh pochv v rayonakh dobychi nefti Zapadnogo Kazakhstana i puti ikh resheniya [Environmental problems of oil-contaminated soils in the oil production regions of Western Kazakhstan and ways to solve them]. Gidrometeorologiya i ekologiya, (3), 111–122. (in Russian).
3. Ministry of Ecology and Natural Resources of the Republic of Kazakhstan. (2023). Natsionalnyi doklad o sostoyanii okruzhayushchei sredy i ob ispolzovanii prirodnkh resursov Respubliki Kazakhstan za 2022 god [National report on the state of the environment and the use of natural resources of the Republic of Kazakhstan for 2022] (p. 71). <https://ecogofond.kz/wp-content/uploads/2023/12/NDSOS-2022-RUS-gotov1-1.pdf> (in Russian).
4. Lassalle, G., Fabre, S., Credo, A., Dubucq, D., & Elger, A. (2020). Monitoring oil contamination in vegetated areas with optical remote sensing: A comprehensive review. Journal of Hazardous Materials, 393, Article 122427. <https://doi.org/10.1016/j.jhazmat.2020.122427>

5. Abbas, D. U. K., & George, L. E. (2022). The detection of oil spill onshore using the thermal band of Landsat-8. TELKOMNIKA (Telecommunication Computing Electronics and Control), 20(2), 383–391. <https://doi.org/10.12928/telkomnika.v20i2.22462>
6. Ozigis, M. S., Kaduk, J. D., & Jarvis, C. H. (2019). Mapping terrestrial oil spill impact using machine learning random forest and Landsat-8 OLI imagery. Environmental Science and Pollution Research, 26, 3621–3635. <https://doi.org/10.1007/s11356-018-3824-y>
7. Kaplan, G., Aydinli, H., Pietrelli, A., Mieleve, F., & Ferrara, V. (2022). Oil-contaminated soil modeling and remediation monitoring in arid areas using remote sensing. Remote Sensing, 14(10), Article 2500. <https://doi.org/10.3390/rs14102500>
8. Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. IEEE Geoscience and Remote Sensing Magazine, 5, 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>
9. Zheng, A., & Casari, A. (2018). Feature engineering for machine learning: Principles and techniques for data scientists. O'Reilly Media.
10. Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. IEEE Transactions on Pattern Analysis and Machine Intelligence, 35(8), 1798–1828. <https://doi.org/10.1109/TPAMI.2013.50>
11. Nurseitov, D. B., Abdimanap, G., Abdallah, A., Sagatdinova, G., Balakay, L., Dedova, T., Rametov, N., & Alimova, A. (2024). ROSID: Remote sensing satellite data for oil spill detection on land. Engineering Sciences, 32, Article 1348. <https://doi.org/10.30919/es1348>
12. EOS Data Analytics. (n.d.). NDVI: Normalized difference vegetation index. Retrieved September 29, 2025, from <https://eos.com/blog/normalized-difference-vegetation-index-or-ndvi/>
13. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84–90. <https://doi.org/10.1145/3065386>
14. Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In V. Ferrari, M. Hebert, C. Sminchisescu, & Y. Weiss (Eds.), Computer vision – ECCV 2018 (pp. 801–818). Springer. https://doi.org/10.1007/978-3-030-01234-2_49
15. Cheng, B., Misra, I., Schwing, A. G., Kirillov, A., & Girdhar, R. (2022). Masked-attention mask transformer for universal image segmentation. In 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 1290–1299). IEEE. <https://doi.org/10.1109/CVPR52688.2022.00135>
16. Rouso, R., Katz, N., Sharon, G., Glizerin, Y., Kosman, E., & Shuster, A. (2022). Automatic recognition of oil spills using neural networks and classic image processing. Water, 14(7), Article 1127. <https://doi.org/10.3390/w14071127>
17. Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). The Pascal visual object classes (VOC) challenge. International Journal of Computer Vision, 88, 303–338. <https://doi.org/10.1007/s11263-009-0275-4>
18. Hossin, M., & Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. International Journal of Data Mining & Knowledge Management Process, 5(2), 1–11. <https://doi.org/10.5121/ijdkp.2015.5201>
19. Rahman, M. A., & Wang, Y. (2016). Optimizing Intersection-over-Union in deep neural networks for image segmentation. In Advances in visual computing: 12th International Symposium, ISVC 2016 (pp. 234–244). Springer. https://doi.org/10.1007/978-3-319-50307-3_11

СЕМАНТИЧЕСКАЯ СЕГМЕНТАЦИЯ НЕФТЯНОГО ЗАГРЯЗНЕНИЯ ЗЕМЕЛЬ ПО СНИМКАМ PLANETSCOPE С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

Ғалымжан С. Әбдіманап*, Татьяна В. Дедова кандидат технических наук, Лариса А. Балакай кандидат технических наук, Данияр Б. Нурсейтов кандидат физико-математических наук, Серик М. Нурақынов PhD.

ТОО «Институт Ионосферы», г. Алматы, Казахстан; g.s.abdimanap@gmail.com (Ғ.С.Ә.), dedova3007@gmail.com (Т.В.Д.), larissabalakay@gmail.com (Л.А.Б.), nurseitovdb@gmail.com (Д.Б.Н.)

*Автор корреспонденции: Ғалымжан С. Әбдіманап, g.s.abdimanap@gmail.com

КЛЮЧЕВЫЕ СЛОВА

замасуленне территория,
дистанционное зондирование,
PlanetScore, глубокое
обучение, семантическая
сегментация

По статье:

Получено: 10.06.2026

Пересмотрено: 16.07.2026

Принято: 17.09.2026

Опубликовано: 30.09.2026

АННОТАЦИЯ

Мониторинг нефтяного загрязнения земель является актуальной задачей для Казахстана. В советское время добыча нефти на некоторых месторождениях осуществлялась амбарным способом, при котором буровые отходы, технологические жидкости и сопутствующие сточные воды собирались в специально вырытых земляных амбарах в непосредственной близости от места добычи, поэтому накопилось большое количество замасуленных территорий, требующих рекультивации с сопутствующим мониторингом. Дистанционное зондирование в совокупности с обработкой снимков методами глубокого обучения, позволяющими более точно сегментировать замасуленные территории, облегчает проведение мониторинга таких территорий. В данной работе представлен датасет ROSID-HR, построенный на основе мультиспектральных снимков PlanetScore, что позволяет сегментировать нефтяное загрязнение малой площади. При создании ROSID-HR в качестве опорной разметки использовались замасуленные участки, входящие в разработанный нами ранее набор данных ROSID, что позволило сохранить согласованность аннотаций между двумя датасетами. Экспериментальным путем установлена оптимальная

композиция каналов PlanetScope (Blue-Red-NIR) для лучшего отделения нефтезагрязненных территорий от теней и техногенных объектов. Для проверки работоспособности датасета была проведена семантическая сегментация с использованием классической модели DeepLabv3+ и трансформерной модели Mask2Former. При использовании архитектуры Mask2Former показатель IoU для класса «нефть» на тестовой выборке составил 69,73%, что в три раза превышает результат модели DeepLabv3+, показавшей 21,63%. Результаты подтверждают эффективность и преимущества совместного использования данных PlanetScope и архитектуры Mask2Former в рамках рассмотренных подходов к выявлению небольших участков, загрязненных нефтью.

SEMANTIC SEGMENTATION OF OIL-CONTAMINATED LAND FROM PLANETSCOPE IMAGERY USING NEURAL NETWORK MODELS

Galymzhan S. Abdimanap*, Tatyana V. Candidate of technical sciences, Dedova PhD, Larissa A. Balakay Candidate of technical sciences, Daniyar B. Nurseitov Candidate of Physical and Mathematical Sciences, Serik M. Nurakynov PhD.

Ionosphere Institute LLP, Almaty, Kazakhstan; g.s.abdimanap@gmail.com (G.S.A.), dedova3007@gmail.com (T.V.D.), larissabalakay@gmail.com (L.A.B.), nurseitovdb@gmail.com (D.B.N.)

*Corresponding author: Galymzhan S. Abdimanap, g.s.abdimanap@gmail.com

KEY WORDS

oil-contaminated lands, remote sensing, PlanetScope, deep learning, semantic segmentation

About article:

Received: 10.06.2026

Revised: 16.07.2026

Accepted: 17.09.2026

Published: 30.09.2026

ABSTRACT

Monitoring of oil-contaminated land is a pressing challenge for Kazakhstan. During the Soviet era, oil production at a number of fields relied on the so-called pit method, whereby drilling waste, process fluids, and associated wastewater were collected in purpose-dug earthen pits adjacent to extraction sites, leaving a substantial legacy of oil-contaminated areas requiring remediation and systematic monitoring. Remote sensing combined with deep learning-based image processing enables more accurate segmentation of such territories and facilitates their ongoing monitoring. This paper presents ROSID-HR, a dataset constructed from PlanetScope multispectral imagery designed for the segmentation of small-area oil contamination. In developing ROSID-HR, oil-contaminated sites from our previously published ROSID dataset were used as reference annotations, ensuring consistency between the two datasets. Through systematic experimentation, the optimal PlanetScope channel configuration for separating oil-contaminated areas from shadows and anthropogenic objects was identified as Blue-Red-NIR (bands 2-6-8). To validate the dataset, semantic segmentation was performed using the convolutional DeepLabv3+ model and the transformer-based Mask2Former architecture. Mask2Former achieved an IoU of 69.73% for the oil class on the test set, exceeding the DeepLabv3+ result of 21.63% by a factor of more than three. The results confirm the effectiveness and advantages of using PlanetScope data and the Mask2Former architecture together as part of the considered approaches to detecting small areas contaminated with oil.

Примечание издателя: заявления, мнения и данные во всех публикациях принадлежат только автору (авторам), а не журналу "Гидрометеорология и экология" и/или редактору (редакторам).