ӘОЖ 004.8:528.8
ҒТАХР 28.23.15
DOI 10.37238/2960-1371.2960-138X.2026.103(3).26

Е.А. Тулегенов, Н.О.Мекебаев*, Ж.А.Орынтаева, Ө.М. Белқожа

Қазақ ұлттық қыздар педагогикалық университеті, Алматы, Қазақстан

E-mail: nurbapa80@gmail.com

ГЕОГРАФИЯЛЫҚ ЗЕРТТЕУДЕ ЖАСАНДЫ ИНТЕЛЛЕКТ НЕГІЗІНДЕ СПУТНИКТІК КЕСКІНДЕРДІ АВТОМАТТЫ ТҮРДЕ ТАЛДАУ

Аңдатпа. Sentinel, Landsat, WorldView, GaoFen және басқа да спутниктік жүйелерден алынатын Жерді қашықтықтан зондтау деректерінің көлемі үздіксіз артып келеді. Мұндай деректерді қолмен талдау көп уақытты қажет ететіндіктен, автоматтандырылған әдістерді қолдану өзекті болып отыр. Мақалада спутниктік кескіндерді терең оқыту арқылы талдаудың заманауи тәсілдері қарастырылды: конволюциялық нейрондық желілер (CNN), семантикалық сегменттеуге арналған U-Net архитектурасы, нысандарды анықтайтын Faster R-CNN және YOLO модельдері, сондай-ақ көріністерді жіктеу мен өзгерістерді анықтауға арналған трансформаторлық модельдер. Ғылыми әдебиеттерге сүйене отырып, аталған тәсілдердің дәлдігі, есептеу тиімділігі және қолданылу салалары салыстырылды. Қарастырылған зерттеулерде EfficientNet негізіндегі модельдер жіктеу дәлдігінің 99,7%-ға дейінгі, назар аудару механизмдерімен толықтырылған U-Net модельдері mIoU көрсеткішінің 81%-ға дейінгі мәндерін көрсеткен. YOLO алгоритмдері нысандарды нақты уақыт режимінде анықтауға мүмкіндік береді. Талдау нәтижесінде Жер бетін кешенді бақылау үшін гибридті CNN–Transformer архитектураларының әлеуеті атап көрсетілді.

Кілт сөздер: жасанды интеллект; жерді қашықтықтан зондтау; спутниктік кескіндер; терең оқыту; конволюциялық нейрондық желілер; семантикалық сегментация.

Кіріспе

Жерді қашықтықтан зондтау деректерін өңдеудің дәстүрлі тәсілдеріне визуалды талдау және тірек векторлар әдісі, кездейсоқ орман, k-орташа кластерлеу сияқты машиналық оқыту алгоритмдері жатады. Бұл тәсілдердің тиімділігі кескіндердің спектрлік және текстуралық ерекшеліктеріне тәуелді, ал үлкен көлемдегі деректерді өңдеу едәуір уақытты қажет етуі мүмкін [1, 4].

Терең оқыту технологияларының пайда болуы мен қарқынды дамуы спутниктік түсірілімдерді автоматты түрде талдау жүйесін түбегейлі жаңа деңгейде көтерді. Сондай-ақ, конволюциялық нейрондық желілер (CNN) белгілерді қолмен сипаттап жатпай-ақ, суреттегі иерархиялық деңгейдегі ерекшеліктерді автоматты түрде бөліп алуға жол ашты. Бұл нысандарды жіктеу, сегменттеу және тану сапасын едәуір арттырды [2, 6]. Нәтижесінде ResNet, DenseNet, EfficientNet және VGG сияқты архитектуралар EuroSAT, UC Merced және NWPU-RESISC45 базалық деректер жиынында 95%-дан жоғары дәлдік көрсетіп, қашықтықтан зондтау суреттерін жіктеудің негізгі тиімді шешімдеріне айналды [1].

Жіктеу тапсырмаларымен қатар, нысандарды (ғимараттар, жолдар, су айдындары мен ауыл шаруашылығы жерлері) пиксель деңгейінде бөліп көрсетуге арналған семантикалық сегменттеу әдістері де қарқынды дамып келеді. Бастапқыда медициналық суреттерді сегменттеу үшін жасалған U-Net архитектурасы уақыт өте келе қашықтықтан зондтау тапсырмаларына бейімделіп, тіпті таңбаланған деректер қоры шектеулі болғанның өзінде жоғары нәтиже көрсетті [7-10]. Ал бұл архитектураның назар аудару (attention) механизмдерімен, көпмасштабты белгілерді біріктіру тәсілдерімен және трансферлік оқытумен толықтырылған жаңа нұсқалары сегменттеу дәлдігін бастапқы U-Net-пен салыстырғанда 10-14%-ға арттыруға мүмкіндік берді [9, 10].

Спутниктік түсірілімдерден нақты нысандарды табу-бөлек әрі күрделі бағыт. Бұл міндетті қиындататын басты факторлар: ізделетін нысандардың шағын мөлшері, олардың тығыз орналасуы, сондай-ақ масштаб пен бағыттың әртүрлі болуы. Осы орайда YOLO (You Only Look Once), Faster R-CNN, SSD сияқты алгоритмдер мен SIMRDWN және YOLT сияқты арнайы шешімдер өте жоғары ажыратымдылықтағы үлкен форматты суреттерді өңдеуге бейімделген [12, 13]. Соңғы жылдары трансформаторлық архитектуралар да (Vision Transformer, Swin Transformer)белсенді дамып келеді. Олар кеңістіктегі алшақ орналасқан байланыстарды да ескеруге мүмкіндік беріп, әртүрлі уақытта түсірілген суреттердегі өзгерістерді анықтау тапсырмаларында жақсы көрсеткіштерге қол жеткізуде [15, 16].

Соңғы жылдардағы жетістіктерге қарамастан, бірнеше мәселе өзекті күйінде қалып отыр: модельдердің жаңа географиялық аймақтарда тұрақты нәтиже көрсетуі, трансформаторлық архитектуралардың есептеу ресурстарына жоғары талап қоюы, сапалы таңбаланған деректердің тапшылығы және алынған нәтижелерді геоақпараттық жүйелерге біріктірудің күрделілігі. Осы мақаланың мақсаты — спутниктік кескіндерді автоматты түрде талдауға арналған жасанды интеллект әдістерін ғылыми әдебиеттер негізінде жүйелеу, салыстыру және олардың дәлдігі мен практикалық қолданылуын бағалау.

Осы мақсатқа жету үшін: 1) спутниктік кескіндерді жіктеу, сегменттеу және нысандарды анықтау әдістері талданды; 2) қашықтықтан зондтау деректерін өңдеудің негізгі кезеңдері сипатталды; 3) жарияланған зерттеулердегі бағалау көрсеткіштері салыстырылды; 4) қолданбалы міндеттерге сәйкес архитектураларды таңдау жөнінде ұсыныстар тұжырымдалды.

Зерттеу материалдары мен әдістері

Қашықтықтан зондтау деректер көздері

Зерттеу барысында қарастырылған ғылыми еңбектерде пайдаланылған деректерге талдау жасалды: Sentinel-2 көпспектрлі түсірілімдері (кеңістіктік ажыратымдылығы 10-20 м), Landsat-8/9 (30 м), WorldView-2/3 пен Gaofan ультра жоғары ажыратымдылықтағы суреттері (0,3-2 м), сондай-ақ модельдерді үйрету мен тестілеуге арналған ашық деректер жиындары-EuroSAT, UC Merced Land Use, NWPU-RESISC45, LandCover.ai, LoveDA, INRIA Aerial Image Labeling, ISPRS Potsdam / Vaihingen және IARPA Functional Map of the World (fMoW) [1, 2, 9, 11]. Аталған деректер қоры жер жамылғысының алуан түрлі санаттарын (орман, су айдындары, қалалық құрылыстар, ауыл шаруашылығы алқаптары, жолдар) және әртүрлі нысан типтерін (ғимараттар, көлік құралдары, кемелер, ұшу аппараттары) толық қамтиды.

Кескінді өңдеудің жалпы әдістемесі

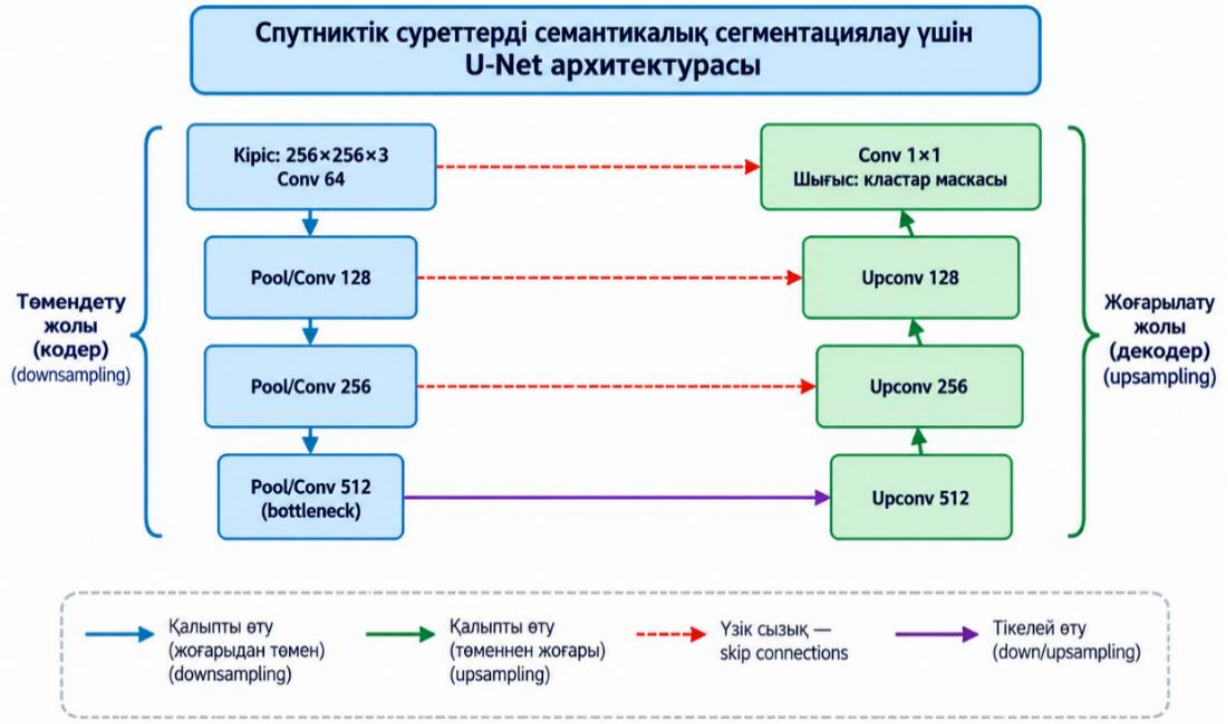
Спутниктік түсірілімдерді автоматты түрде талдаудың үлгілік жұмыс үдерісі тізбекті бес кезеңнен тұрады: бастапқы мәліметтерді өңдеу, оқыту таңдамасын қалыптастыру, жасанды интеллект моделін қолдану, нәтижелерді кейінгі өңдеу және оларды геоақпараттық жүйелерге кіріктіру (1-сурет). Алдын ала өңдеу радиометриялық және атмосфералық түзетуді, бұлттылықтың әсерін жоюды, ортотрансформацияны және спектрлік арналарды қалыпқа келтіруді қамтиды. Бастапқы суреттер нейрондық желінің кіріс тензорының рұқсат етілген мөлшерінен едәуір асып кететіндіктен, кескіндер сәйкес келетін бекітілген өлшемді плиткаларға бөлінеді (әдетте 256×256 немесе 512×512 пиксель), бұл нәтижені кейіннен жинау кезінде шеттік әсерлерді азайтуға мүмкіндік береді.



1-сурет – Жасанды интеллект әдістерін қолдана отырып, спутниктік кескіндерді автоматты түрде талдаудың жалпыланған схемасы

Терең оқыту модельдерінің архитектурасы

Көріністерді жіктеу мәселесін шешу үшін конволюциялық архитектуралар (VGG16, ResNet50/101, DenseNet121, InceptionV3, EfficientNet) және трансформаторлық модельдер (Vision Transformer, Swin Transformer) қолданылады, олар кіріс кескінінен белгілерді шығарады және толық байланыстырылған классификатор арқылы оны жер жамылғысының алдын-ала анықталған кластарының біріне жатқызады [1, 2, 4]. Семантикалық сегменттеу мәселесі үшін негізгі архитектура-симметриялы "кодтаушы — декодтаушы" құрылымы бар U-Net-конволюциялық желі және төмен деңгейлі кеңістіктік белгілердің кодтаушыдан декодтаушыға өтуін қамтамасыз ететін skip қосылымдары (2-сурет) [7-10]. U-Net заманауи модификациялары кеңістіктік және арналық зейін модульдерімен (CBAM, SE-блоктар) толықтырылады, сондай-ақ Transfer learning әдіснамасы бойынша кодтаушыны инициализациялау үшін ImageNet backbone-желілерінде (ResNet, VGG16, EfficientNet) алдын ала оқытылғандарды пайдаланады [9].



2-сурет – Спутниктік кескіндерді семантикалық сегментациялау үшін U-Net архитектурасының жеңілдетілген схемасы

Нысанды анықтау тапсырмасы үшін бір сатылы детекторлар (YOLOv3/v5/V8, SSD) және екі сатылы детекторлар (Faster R-CNN), сондай — ақ үлкен форматты суретке түсіруге мамандандырылған шешімдер қарастырылды-SIMRDWN және YOLT, терезені ("плитканы") сканерлеуді жүзеге асырады, содан кейін нәтижелерді біріктіреді [12, 13, 25]. Әр түрлі уақыттағы суреттер арасындағы өзгерістерді анықтау тапсырмасы үшін сиамдық конволюциялық желілер, сондай-ақ трансформаторлық модельдер (VcT, TransUNetCD, Swin-Transformer) қолданылады, бұл "бұрын/кейін" кескін жұптары арасындағы жергілікті және ғаламдық кеңістіктік тәуелділіктерді ескеруге мүмкіндік береді [15, 16].

Қарастырылған модельдер кластарын, олардың архитектуралық шешімдерін, артықшылықтары мен шектеулерін жалпылама салыстыру 1-кестеде келтірілген.

1-кесте – Спутниктік кескіндерді талдауға арналған ЖИ тәсілдерінің салыстырмалы сипаттамасы

Міндеттер	**Типтік архитектуралар**	**Артықшылықтары**	**Шектеулер**
Көріністердің жіктелуі	VGG16, ResNet, DenseNet, EfficientNet, ViT	Жоғары дәлдік, оқудың қарапайымдылығы, көптеген алдын ала дайындалған салмақтар	Объектінің кеңістіктік орналасуын бермейді
Семантикалық сегментация	U-Net, SegNet, DeepLabV3+, MACU-Net	Пиксель деңгейінде дәл жіктеу, шағын үлгідегі жұмыс	Жоғары есептеу жүктемесі, шекара шуына сезімталдық

Нысандарды анықтау	YOLOv5/v8, Faster R-CNN, SSD, SIMRDWN	Жоғары жылдамдық (YOLO), дәл локализация (Faster R-CNN)	Шағын және тығыз орналасқан объектілерді анықтаудың қиындығы
Өзгерістерді анықтау	Siamese CNN, VcT, TransUNetCD, Swin-Transformer	Ұзақ мерзімді тәуелділіктерді есепке алу, маусымдық айырмашылықтарға төзімділік	Көп көлемдегі әртүрлі таңбаланған деректерді қажет етеді

Модельдердің сапасын бағалау көрсеткіштері

Зерттелген көздердегі модельдердің тиімділігін сандық бағалау үшін қашықтықтан зондтау кескіндерін өңдеу тапсырмаларына бейімделген стандартты машиналық оқыту көрсеткіштерінің жиынтығы қолданылды (2-кесте). Нақты метриканы таңдау шешілетін мәселенің түрімен анықталады: жіктеу үшін accuracy және F1-өлшем, сегменттеу үшін - IoU/mIoU көрсеткіші, объектілерді анықтау үшін - mAP (mean Average Precision), ал нақты уақыттағы қосымшалар үшін модельдің инференс уақыты қосымша ескеріледі.

2-кесте – Жасанды интеллект модельдерінің сапасын бағалау көрсеткіштері

Метрика	Формула / тағайындау
Accuracy (дәлдік)	Барлық бақылаулар ішіндегі дұрыс жіктелген пикселдердің/көріністердің үлесі
Precision / Recall	Оң класты анықтаудың дәлдігі мен толықтығы; тепе-теңдік F1 өлшемін көрсетеді
F1-score	Precision және Recall метрикаларының гармониялық орташа мәні, кластардың теңгерімсіздігі жағдайында тұрақты көрсеткіш болып табылады.
IoU / mIoU	Болжанған және нақты маскалардың қиылысу ауданының бірігу ауданына қатынасы; сегменттеудің негізгі көрсеткіші
mAP	Барлық объектілер кластары мен IoU шектері бойынша анықтаудың орташа дәлдігі
Инференс уақыты	Бір кескінді/плитканы өңдеу уақыты, жедел бақылау үшін өте маңызды

Салыстырмалы талдау жарияланған зерттеулердегі сандық нәтижелерді жүйелеу арқылы жүргізілді [1–16]. Көрсеткіштер диаграммалар түрінде ұсынылды. Әртүрлі деректер жиындары мен эксперименттік жағдайларда алынған нәтижелер тікелей салыстыруға әрдайым келе бермейтіндіктен, олар модельдердің ықтимал артықшылықтары мен шектеулерін сипаттау үшін пайдаланылды.

Зерттеу нәтижелері

Спутниктік кескіндерді жіктеу архитектураларын салыстыру

Әдеби деректерді талдау жер жамылғысын жіктеудің дәлдігі таңдалған нейрондық желі архитектурасына айтарлықтай тәуелді екенін көрсетті (3-сурет). Классикалық VGG16 және ResNet50 желілері сәйкесінше 93,4% және 95,1% дәлдікті қамтамасыз етеді, бұл қазіргі заманғы архитектуралардан төмен. Ең жақсы нәтижелерді EfficientNet-B7 моделі көрсетті, ол желінің тереңдігін, енін және ажыратымдылығын

тиімді масштабтау арқылы RSI-cb256 деректер жиынында 99,7% дәлдікке қол жеткізді [3]. Трансформаторлық модельдер (Vision Transformer) 97,2% дәлдікті көрсетті, классикалық CNN — ден асып түсті, бірақ EfficientNet-тен төмен-бұл нәтиже салыстырмалы зерттеудің қорытындысын растайды [2] гибридті және композиттік масштабтау модельдері бүгінгі күнге дейін ЖҚЗ көріністерін жіктеу есептері үшін ең тиімді шешім болып қала береді.



3-сурет – спутниктік кескіндерді жіктеу кезінде терең оқыту архитектураларының дәлдігін салыстыру ([1-4] мәліметтері бойынша)

YOLOv3 алгоритмі Faster R-CNN - мен салыстырғанда 94,2% дәлдікті көрсетті, бұл оны нақты уақыт режимінде кемелерді, көлік құралдарын және инфрақұрылымдық нысандарды анықтауды жедел бақылау міндеттері үшін таңдаулы таңдау етеді. Екі бағытты белгілер пирамидасын (BiFPN) қолдана отырып, YOLOv8-ге негізделген BA-YOLO модификациясы әр түрлі масштабты белгілердің бірігуі арқылы күрделі фондық суреттердегі ұсақ объектілерді анықтау дәлдігінің қосымша жақсарғанын көрсетті [12]. SSD әдісі қарастырылған алгоритмдер арасында ең аз дәлдікті (84,61%) көрсетті, бірақ өңдеу жылдамдығының артықшылығын сақтайды, бұл оны дәлірек, бірақ ресурстарды қажет ететін модельдерді қолданар алдында кадрларды алдын ала сүзу тапсырмаларына жарамды етеді.

Өзгерістерді анықтау және трансформаторлық архитектуралар

Спутниктік түсірілімдерді талдаудың бөлек бір бағыты-әртүрлі уақыт кезеңіндегі суреттер бойынша жер жамылғысының өзгерістерін анықтау. Бұл — заңсыз ормандардың оталуын, қала құрылысының барысын, табиғи апаттар салдары мен антропогендік әсерлерді бақылауда аса маңызды міндет. Сиамдық сверткалық желілерге негізделген дәстүрлі тәсілдер жергілікті өзгерістерді тиімді анықтағанымен, суреттің жалпы (жаһандық) контекстін толық ескере алмайды [15]. Ал трансформаторлық архитектуралар, соның ішінде VCT (Visual Change Transformer) моделі бұл түйткілді өзіндік назар аудару (self-attention) механизмі арқылы шешеді. Ол өзгерген аймақтармен қатар тұрақты фондық контекстті де талдауға мүмкіндік беріп, түрлі уақыттағы кадрлардағы маусымдық әрі жарықтандыру ауытқуларына модельдің

төзімділігін арттырады [15]. Ұқсас нәтижелер [16] зерттеуінде алынған, мұнда иерархиялық трансформаторлық архитектура кеңейтілген рецептивті өріс және ұзақ мерзімді кеңістіктік тәуелділіктерді есепке алу арқылы ультра жоғары ажыратымдылықтағы кескіндердегі өзгерістерді анықтау дәлдігі бойынша конволюциялық аналогтардан асып түсті.

Талдау спутниктік кескіндерді өңдеудің барлық міндетіне бірдей тиімді әмбебап архитектура жоқ екенін көрсетті. Модельді таңдау кезінде дәлдік, есептеу шығыны және таңбаланған деректердің қолжетімділігі ескерілуі қажет. Қарастырылған әдебиеттерге сәйкес, көріністерді жіктеуде EfficientNet, семантикалық сегменттеуде назар аудару механизмдерімен толықтырылған U-Net, нысандарды жедел анықтауда YOLO, ал өзгерістерді бақылауда CNN мен трансформаторларды біріктіретін модельдер перспективалы болып саналады.

Қорытынды

Зерттеу барысында спутниктік кескіндерді автоматты түрде талдауға арналған заманауи жасанды интеллект тәсілдері жүйеленіп, олардың дәлдігі, есептеу тиімділігі және қолданылу салалары салыстырылды. Қарастырылған әдебиеттерде жер жамылғысын жіктеу дәлдігінің 99,7%-ға дейін, семантикалық сегменттеудің mIoU көрсеткішінің 81,3%-ға дейін және нысандарды анықтаудың mAP көрсеткішінің 97,0%-ға дейін жеткені хабарланған. Бұл мәндер әртүрлі зерттеулерден алынғандықтан, оларды бірыңғай эксперимент нәтижесі ретінде түсіндіруге болмайды.

Әдебиеттерді салыстыру EfficientNet архитектураларының көріністерді жіктеуде, назар аудару механизмдері бар U-Net нұсқаларының семантикалық сегменттеуде, ал YOLO модельдерінің нысандарды жедел анықтауда тиімді қолданылатынын көрсетті. VcT және Swin Transformer сияқты трансформаторлық архитектуралар кеңістіктік контекстті есепке алу арқылы әртүрлі уақыттағы кескіндер арасындағы өзгерістерді анықтауға мүмкіндік береді.

Алынған нәтижелер ауыл шаруашылығы, экологиялық бақылау, қала құрылысын жоспарлау және қауіпсіздікті қамтамасыз ету мақсатында жер бетін бақылаудың автоматтандырылған жүйелерін әзірлеу кезінде пайдаланылуы мүмкін. Әрі қарайғы зерттеулердің перспективалық бағыттары борттық деректерді өңдеуге арналған жеңіл (lightweight) модельдерді әзірлеу, оптикалық және радиолокациялық деректерді біріктіретін мультимодальды архитектураларды құру, сондай-ақ жаңа географиялық аймақтарға және датчиктердің түрлеріне көшу кезінде модельдердің жалпылау қабілетін арттыру болып табылады.

ӘДЕБИЕТ

[1]. Adegun A.A., Viriri S., Tapamo J.R. Review of deep learning methods for remote sensing satellite images classification: experimental survey and comparative analysis // Journal of Big Data. – 2023. – Vol. 10. – Art. 93. DOI: 10.1186/s40537023-00772-x

[2]. Kumar G., Kokila S. A . Comprehensive Review on Deep Learning Model for Multi Class Satellite Image Classification // International Journal for Research in Applied Science & Engineering Technology (IJRASET). – 2024. – Vol. 12, № 3. DOI: 10.22214/ijraset.2024.58035

[3]. Tehsin S., Kausar S., Jameel A., Humayun M., Almofarreh D.K. Satellite Image Categorization Using Scalable Deep Learning // Applied Sciences. – 2023. –Vol. 13, № 8. – Art. 5108. DOI: 10.3390/app13085108

[4]. Deep Learning Approaches For Satellite Image Classification: A Review // International Journal of Environmental Sciences. – 2025. – P. 1480–1491. DOI: 10.64252/nd9d9c89

[5]. A Systematic Review of Satellite Image Classification // International Journal of Machine Learning. – 2025. –Vol. 15, № 3. –P. 51-63. DOI: 10.18178/ijml.2025.15.3.1179

[6]. Pritt M., Chern G. Satellite Image Classification with Deep Learning // Proceedings of the IEEE Applied Imagery Pattern Recognition Workshop (AIPR). –Washington, 2017. DOI: 10.1109/AIPR.2017.8457969

[7]. Semantic segmentation of remote sensing images combined with attention mechanism and feature enhancement U-Net // International Journal of Remote Sensing. – 2023. –Vol. 44, № 19. DOI: 10.1080/01431161.2023.2264502

[8]. Dimitrovski I., Spasev V., Loshkovska S., Kitanovski I. U-Net Ensemble for Enhanced Semantic Segmentation in Remote Sensing Imagery // Remote Sensing. – 2024. – Vol. 16, № 12. – Art. 2077. DOI: 10.3390/rs16122077

[9]. Zhang H., Jiang Z., Zheng G. et al. Semantic Segmentation of High-Resolution Remote Sensing Images with Improved U-Net Based on Transfer Learning // International Journal of Computational Intelligence Systems. – 2023. – Vol. 16. – Art. 181. DOI: 10.1007/s44196-023-00364-w

[10]. Su Z., Li W., Ma Z. et al. An improved U-Net method for the semantic segmentation of remote sensing images // Applied Intelligence. – 2022. – Vol. 52. – P. 3276–3288. DOI: 10.1007/s10489-021-02542-9

[11]. Li X., Li J. MFCA-Net: a deep learning method for semantic segmentation of remote sensing images // Scientific Reports. – 2024. – Vol. 14. DOI: 10.1038/s41598-024-56211-1

[12]. BA-YOLO for Object Detection in Satellite Remote Sensing Images // Applied Sciences. – 2023. – Vol. 13, № 24. –Art. 13122. DOI: 10.3390/app132413122

[13]. Tahir A., Munawar H.S., Akram J., Adil M., Ali S., Kouzani A.Z., Mahmud M.A.P. Automatic Target Detection from Satellite Imagery Using Machine Learning // Sensors. – 2022. –Vol. 22, № 3. –Art. 1147. DOI: 10.3390/s22031147

[14]. Cinarer G. et al. Detection of Aerial Vehicles Using Satellite Imagery: Comparative Analysis of U-Net Segmentation Model and YOLO Object Detection Model // International Journal of Aerospace Engineering. – 2025. DOI: 10.1155/ijae/5599522

[15]. Jiang B., Wang X., Zheng A. et al. VcT: Visual Change Transformer for Remote Sensing Image Change Detection // IEEE Transactions on Geoscience and Remote Sensing. – 2023. – Vol. 61. DOI: 10.1109/TGRS.2023.3327139

[16]. Deep hierarchical transformer for change detection in high-resolution remote sensing images // GIScience & Remote Sensing. – 2023. –Art. 2196641. DOI: 10.1080/22797254.2023.2196641

REFERENCES

[1]. Adegun A.A., Viriri S., Tapamo J.R. Review of deep learning methods for remote sensing satellite images classification: experimental survey and comparative analysis // Journal of Big Data. – 2023. – Vol. 10. – Art. 93. DOI: 10.1186/s40537023-00772-x

[2]. Kumar G., Kokila S. A . Comprehensive Review on Deep Learning Model for Multi Class Satellite Image Classification // International Journal for Research in Applied Science

& Engineering Technology (IJRASET). – 2024. – Vol. 12, № 3. DOI: 10.22214/ijraset.2024.58035

[3]. Tehsin S., Kausar S., Jameel A., Humayun M., Almofarreh D.K. Satellite Image Categorization Using Scalable Deep Learning // Applied Sciences. – 2023. –Vol. 13, № 8. – Art. 5108. DOI: 10.3390/app13085108

[4]. Deep Learning Approaches For Satellite Image Classification: A Review // International Journal of Environmental Sciences. – 2025. – P. 1480–1491. DOI: 10.64252/nd9d9c89

[5]. A Systematic Review of Satellite Image Classification // International Journal of Machine Learning. – 2025. –Vol. 15, № 3. –P. 51-63. DOI: 10.18178/ijml.2025.15.3.1179

[6]. Pritt M., Chern G. Satellite Image Classification with Deep Learning // Proceedings of the IEEE Applied Imagery Pattern Recognition Workshop (AIPR). –Washington, 2017. DOI: 10.1109/AIPR.2017.8457969

[7]. Semantic segmentation of remote sensing images combined with attention mechanism and feature enhancement U-Net // International Journal of Remote Sensing. – 2023. –Vol. 44, № 19. DOI: 10.1080/01431161.2023.2264502

[8]. Dimitrovski I., Spasev V., Loshkovska S., Kitanovski I. U-Net Ensemble for Enhanced Semantic Segmentation in Remote Sensing Imagery // Remote Sensing. – 2024. – Vol. 16, № 12. – Art. 2077. DOI: 10.3390/rs16122077

[9]. Zhang H., Jiang Z., Zheng G. et al. Semantic Segmentation of High-Resolution Remote Sensing Images with Improved U-Net Based on Transfer Learning // International Journal of Computational Intelligence Systems. – 2023. – Vol. 16. – Art. 181. DOI: 10.1007/s44196-023-00364-w

[10]. Su Z., Li W., Ma Z. et al. An improved U-Net method for the semantic segmentation of remote sensing images // Applied Intelligence. – 2022. – Vol. 52. – P. 3276–3288. DOI: 10.1007/s10489-021-02542-9

[11]. Li X., Li J. MFCA-Net: a deep learning method for semantic segmentation of remote sensing images // Scientific Reports. – 2024. – Vol. 14. DOI: 10.1038/s41598-024-56211-1

[12]. BA-YOLO for Object Detection in Satellite Remote Sensing Images // Applied Sciences. – 2023. – Vol. 13, № 24. –Art. 13122. DOI: 10.3390/app132413122

[13]. Tahir A., Munawar H.S., Akram J., Adil M., Ali S., Kouzani A.Z., Mahmud M.A.P. Automatic Target Detection from Satellite Imagery Using Machine Learning // Sensors. – 2022. –Vol. 22, № 3. –Art. 1147. DOI: 10.3390/s22031147

[14]. Cinarer G. et al. Detection of Aerial Vehicles Using Satellite Imagery: Comparative Analysis of U-Net Segmentation Model and YOLO Object Detection Model // International Journal of Aerospace Engineering. – 2025. DOI: 10.1155/ijae/5599522

[15]. Jiang B., Wang X., Zheng A. et al. VcT: Visual Change Transformer for Remote Sensing Image Change Detection // IEEE Transactions on Geoscience and Remote Sensing. – 2023. – Vol. 61. DOI: 10.1109/TGRS.2023.3327139

[16]. Deep hierarchical transformer for change detection in high-resolution remote sensing images // GIScience & Remote Sensing. – 2023. –Art. 2196641. DOI: 10.1080/22797254.2023.2196641

Е.А. Тулегенов, Н.О. Мекебаев, Ж.А. Орынтаева, Ө.М. Белқожа

АВТОМАТИЧЕСКИЙ АНАЛИЗ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ГЕОГРАФИЧЕСКИХ ИССЛЕДОВАНИЯХ

Аннотация. Стремительный рост объёма данных дистанционного зондирования Земли, поступающих от спутниковых группировок нового поколения (Sentinel, Landsat, WorldView, GaoFen и др.), делает ручную интерпретацию изображений практически невозможной и обусловливает необходимость внедрения методов искусственного интеллекта. В статье рассматриваются современные подходы к автоматическому анализу спутниковых изображений на основе глубокого обучения, включая сверточные нейронные сети (CNN), архитектуры типа U-Net для семантической сегментации, детекторы объектов семейства YOLO и Faster R-CNN, а также трансформерные модели для задач классификации сцен и обнаружения изменений. Предложена обобщённая методика обработки данных, охватывающая этапы от предварительной обработки и аугментации до постобработки результатов и их географической привязки. На основе анализа литературных источников проведено сравнение основных алгоритмических подходов по точности, вычислительной эффективности и области применения; результаты представлены в виде таблиц и диаграмм. Архитектуры на основе EfficientNet и трансформеров демонстрируют наиболее высокую точность классификации (до 99,7%), модели семейства U-Net с механизмами внимания превосходят классические подходы в задачах сегментации (mIoU до 81%), а алгоритмы YOLO обеспечивают оптимальный баланс между скоростью и точностью при обнаружении объектов в режиме реального времени. Сделан вывод о перспективности гибридных CNN–Transformer архитектур для комплексного мониторинга земной поверхности.

Ключевые слова: искусственный интеллект; дистанционное зондирование Земли; спутниковые изображения; глубокое обучение; сверточные нейронные сети; семантическая сегментация.

E. Tulegenov, N. Mekebayev, Zh. Oryntayeva, O. Belkozha

AUTOMATIC ANALYSIS OF SATELLITE IMAGERY USING ARTIFICIAL INTELLIGENCE IN GEOGRAPHICAL RESEARCH

Annotation. The rapid growth in the volume of Earth remote sensing data acquired from new-generation satellite constellations (Sentinel, Landsat, WorldView, GaoFen, etc.) makes manual image interpretation increasingly impractical and necessitates the adoption of artificial intelligence methods. This article reviews modern deep learning approaches to the automatic analysis of satellite imagery, including convolutional neural networks (CNNs), U-Net-type architectures for semantic segmentation, object detectors from the YOLO and Faster R-CNN families, and Transformer-based models for scene classification and change detection. A generalized data-processing methodology is proposed, covering the entire workflow from preprocessing and data augmentation to post-processing and georeferencing of the obtained results. Based on an analysis of the relevant literature, the major algorithmic approaches are compared in terms of accuracy, computational efficiency, and areas of application, with the results presented in tables and diagrams. EfficientNet- and Transformer-based architectures demonstrate the highest classification accuracy (up to 99.7%), U-Net-family models incorporating attention mechanisms outperform conventional approaches in segmentation tasks (with mIoU values of up to 81%), while YOLO algorithms provide an effective balance

between speed and accuracy for real-time object detection. The study concludes that hybrid CNN–Transformer architectures represent a promising direction for comprehensive Earth surface monitoring.

Keywords: artificial intelligence; Earth remote sensing; satellite imagery; deep learning; convolutional neural networks; semantic segmentation.