

Код МРНТИ 38.49.31

Э.О. Орынбасарова, *Б. Адебиев, О. Байтурбай, М.К. Закария
Satbayev University (Алматы қ., Қазақстан)

АҚТОҒАЙ МЫС-ПОРФИРЛІ КЕН ОРНЫНЫҢ МЫСАЛЫНДА ГИДРОТЕРМИЯЛЫҚ ӨЗГЕРГЕН АЙМАҚТАРДЫ ЖІКТЕУҮҮШІН МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНУ

Аннотация. Мақалада Ақтоғай мыс-порфирлі кен орнын мысалға ала отырып, гидротермалды өзгерген аймақтарды жіктеу үшін машиналық оқыту алгоритмдерін қолдану нәтижелері қарастырылады. Зерттеу ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) спутнигінің мультиспектралды деректері, сондай-ақ далалық және зертханалық зерттеу нәтижелері негізінде жүргізілді. Жіктеу нәтижелері бойынша максималды ықтималдық әдісі ең жоғары тиімділікті көрсетті: жалпы дәлдік – 84,12%, Каппа коэффициенті – 0,79. Ал минималды қашықтық әдісінің дәлдігі 54%-ды, Каппа коэффициенті 0,39-ды құрады. Бұл нәтижелер гидротермалды өзгерген аймақтарды автоматты түрде карталауда машиналық оқыту алгоритмдерінің әлеуетін растайды.

Түйінді сөздер: машиналық оқыту, гидротермиялық өзгерістер, мыс-порфирлі кен орындары, ASTER, максималды ықтималдылық, минималды қашықтық.

Application of machine learning algorithms for classification of hydrothermally altered areas on the example of the Aktogay porphyry copper deposit

Abstract. This article presents the results of applying machine learning algorithms to classify hydrothermally altered zones, using the Aktogay porphyry copper deposit as a case study. The research is based on multispectral data from the ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) satellite, as well as field and laboratory investigations. According to the classification results, the maximum likelihood algorithm demonstrated the highest effectiveness, with an overall accuracy of 84.12% and a Kappa coefficient of 0.79. The minimum distance algorithm showed an accuracy of 54%, with a Kappa coefficient of 0.39. These findings confirm the potential of machine learning algorithms for the automated mapping of hydrothermally altered zones.

Key words: machine learning, hydrothermal alterations, porphyry copper deposits, ASTER, maximum likelihood, minimum distance.

Использование алгоритмов машинного обучения для классификации гидротермально измененных областей на примере медно-порфирового месторождения Актотай

Аннотация. В статье рассматриваются результаты применения алгоритмов машинного обучения для классификации гидротермально измененных зон на примере медно-порфирового месторождения Актотай. Исследование выполнено на основе мультиспектральных данных спутника ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer), а также данных полевых и лабораторных исследований. По результатам классификации наивысшую эффективность показал метод максимального правдоподобия: общая точность составила 84,12%, коэффициент Каппа – 0,79. Метод минимального расстояния продемонстрировал точность 54%, при коэффициенте Каппа – 0,39. Полученные результаты подтверждают потенциал алгоритмов машинного обучения для автоматизированного картографирования гидротермально измененных зон.

Ключевые слова: машинное обучение, гидротермальные изменения, медно-порфировые месторождения, ASTER, максимальное правдоподобие, минимальное расстояние.

Кіріспе

Гидротермалды өзгерістер пайдалы қазбалар кен орындарының, әсіресе Қазақстанда кең таралған мыс-порфирлі кен орындарының негізгі индикаторларының бірі болып саналады. Мыс-порфирлі кен орындары филлиттік, аргиллиттік, калийлік және пропилиттік сияқты типтік гидротермалды өзгерген аймақтармен сипатталады. Осындай аймақтарды дәл анықтау және карталау күрделі мәселе болып табылады, ал бұл мәселені тиімді шешу геологиялық барлау және кен өндіру жұмыстарының тиімділігін арттыруға тікелей әсер етеді¹.

Соңғы жылдары геологиялық барлау мақсатында Жерді қашықтықтан зондау (ЖҚЗ) әдістері, оның ішінде мультиспектралды және гиперспектралды түсірілімдерді қолдану белсенді түрде қолданып келеді. Бұл деректер минералдарды карталаудың дәлдігі мен жылдамдығын едәуір арттыруға мүмкіндік береді. Дегенмен мультиспектралды мәліметтерді пайдалануда кездесетін дәстүрлі әдістердің (мысалы, визуалды дешифрлеу, индекстерді есептеу) бір-қатар кемшіліктері бар. Атап айтқанда, бұл әдістер спектралдық қолтаңбалары күрделі минералдарды анықтауда жеткілікті дәлдік көрсетпейді, ал талдау нәтижелері субъективтілікке бейім келеді [1].

Соңғы жылдары мұндай мәселелерді шешуде спектралдық мәліметтерден жасырын заңдылықтарды анықтау арқылы талдаудың дәлдігін арттыратын машиналық

оқыту алгоритмдері кеңінен қолданыла бастады [2, 3]. Мысалы, бұл мақалада [4] авторлар ASTER деректері және қолдау векторлық машинасы алгоритмдерін Израильдің Беэр-Шева аймағындағы жер бетінің түрлерін жіктеу үшін қолданды. Тірек векторлары әдісі алгоритмінің ASTER мәліметтерін жіктеу кезінде жоғары тиімділігін көрсетті. Келесі зерттеуде [5] максималды ықтималдылық және минималды қашықтық әдістері салыстырылды. Landsat спутниктік деректері негізінде жерді пайдалану және жер жамылғысын жіктеу негізінде карталау жүргізілді. Нәтижелерге сәйкес, максималды ықтималдылық әдісі жоғары дәлдік көрсетті, ал минималды қашықтық әдісі есептеу тұрғысынан жеңіл болғанымен, жіктеу дәлдігі төмен болды. Бұл зерттеу максималды ықтималдылық алгоритмінің күрделі жіктеу тапсырмалары үшін тиімділігін дәлелдеді.

Сонымен қатар, жекелеген зерттеулердің болғанына карамастан, Қазақстандағы мыс-порфирлі кен орындарының гидротермалды өзгерген аймақтарын жіктеуде түрлі машиналық оқыту алгоритмдерінің тиімділігін кешенді бағалау әлі жүргізілген жоқ. Осыған байланысты, бұл жұмыстың мақсаты – ASTER мультиспектралды деректері негізінде Ақтоғай мыс-порфирлі кен орны мысалында гидротермалды өзгерген зоналарды жіктеу үшін машиналық оқыту алгоритмдерінің тиімділігін бағалау және оларды салыстырмалы талдау болып табылады.

¹Innoter: ақпараттық нормал. URL: <https://innoter.com/articles/poisk-gidrottermalno-izmenennykh-porod-dlya-vyyavleniya-medno-porfirovyykh-mestorozhdeniy-s-potomoshchyu/> (қаралған күні: 13.03.2025). Қолжетімділік режимі: ашық.

Алынған нәтижелер Қазақстан аумағындағы геологиялық-барлау және кен іздеу жұмыстарының тиімділігін арттыру үшін пайдалы болады, сондай-ақ ұқсас кен орындарындағы гидротермалды өзгерген аймақтарды автоматтандырылған карталауда тиімді машиналық оқыту әдістерін анықтауға мүмкіндік береді.

Әдістері мен материалдары

Зерттеу аумағы. Зерттеу аумағы ретінде Жоңғар-Балқаш қатпарлы жүйесіне кіретін және күрделі геологиялық құрылысымен ерекшеленетін Колдар массивінде орналасқан Ақтоғай мыс-порфирлі кен орны таңдалды. Бұл массивтің геологиялық құрылымы күрделі болып келеді және өңірдегі мыс-порфир типті минералданумен байланысты негізгі объектілердің бірі болып саналады.

Колдар массиві негізінен диориттер мен гранодиориттерден құралған интрузивті лакколит болып табылады. Массивтің ашылған беті батыстан шығысқа қарай шамамен 17 км және жалпы шамамен 75 км² аумақты қамтиды. Геофизикалық зерттеулердің нәтижелері бойынша массивтің 1 мен 2 км-ге дейінгі тереңдіктегі бөліктері шамамен 216 км² аумақты алып жатыр. Массивтің негізгі бөлігі тереңдігі 4,7 км-ге дейін жететін бірнеше желі қалыптастырады, олардың ішіндегі бастысы Ақтоғай және Айдарлы кен орындарының арасында жатыр².

Ақтоғай мыс-порфир кен орны массивтің шығыс бөлігінде орналасқан. Бұл кен орны геологиялық зерттеудің жоғары дәрежесіне және геологиялық барлау жұмыстарының егжей-тегжейлі деректерінің болуына байланысты анықтамалық аудан ретінде таңдалды. Негізгі кен минералдары халькопирит, борнит және халькозинмен ұсынылған. Кендердегі мыстың орташа мөлшері шамамен 0,39%, ал Молибден шамамен 0,01% құрайды [6].

Бастапқы деректер. Бастапқы деректер ретінде ресми Earth Data порталынан алынған бұлттылығы және өсімдік жамылғысы минималды деңгейдегі ASTER мультиспектралды спутниктік дерегі пайдаланылды. Қолданылған деректің түсірілім уақыты 2004 жылдың 14 тамызы, деңгейі L1A. Зерттеу барысында тек көрінетін және жақын инфрақызыл арналары қолданылды. ASTER деректерінің таңдалуы оның гидротермалды өзгерістермен байланысты минералдардың спектралды сипаттамаларын тіркеуге қабілеттілігімен негізделеді. ASTER деректері 14 спектралды арнаны, оның ішінде 3 көрінетін, 6 жақын инфрақызыл және 5 жылулық инфрақызыл диапазондарын қамтиды. ASTER мәліметтерінің маңызды артықшылықтарына тегін қолжетімділік, көрінетін және жақын инфрақызыл арналарында жоғары кеңістіктік ажыратымдылық (15 және 30 м сәйкесінше), сондай-ақ мыс-порфирлі кен орындарына тән минералдарды жіктеу үшін маңызды болып табылатын жақын инфрақызыл арнасында басқа мультиспектралды түсірілімдерге Landsat 8 OLI/TIRS (2 арна) және Sentinel 2 (3 арна) қарағанда көбірек спектралдық арналардың (9 арна) болуын жатқызуға болады.

Бастапқы деректердің маңызды бөлігін әртүрлі дереккөздерінен жиналған бақылау нүктелері базасы құрайды, оның қатарында:

- 103 бақылау нүктесі – «Kaz minerals» компаниясы ұсынған бақылау нүктелері, олар бұрғылау және зертханалық зерттеулер нәтижелеріне негізделген;

- 397 бақылау нүктесі – зерттеу аумағының деталды геологиялық карталарын цифрлау арқылы алынған бақылау нүктелері.

Жалпы алғанда филлиттік аймақ бойынша – 93, аргилиттік – 132, калийлік – 149 және пропилиттік – 126 бақылау нүктелері қолданылды. Бұл деректер машиналық оқыту және жіктеу дәлдігін бағалау үшін қажетті бақылау нүктелері базасын жасау мақсатында пайдаланылды.

Зерттеу әдістері. Зерттеу келесі кезеңдерден тұрады:

- ASTER спутниктік түсірілімінің алдын ала өңделуі ENVI бағдарламалық жасақтамасында жүргізілді және радиометриялық калибрлеу, Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes (FLAASH) әдісін қолдану арқылы атмосфералық түзету кезеңдерін қамтыды.

- Бақылау базасы негізінде ENVI бағдарламалық жасақтамасында қызығушылық аймақтары құрылды. Бұл кезеңде алынған мәліметтер оқыту және бақылау жиынтықтарына бөлінді (80% – оқыту, 20% – бақылау).

- Қызығушылық аймақтары қалыптастырылғаннан кейін олардың өзара айырымдылығы бағаланды. ENVI бағдарламалық жасақтамасында қызығушылық аймақтары арасындағы айырмашылықтарды бағалау үшін айырымдылық матрицасы пайдаланылды [7]. Бұл кезең жоғары бөліну деңгейіне ие класстарды анықтау, сондай-ақ нашар ажыратылатын класстарды біріктіру немесе қайта белгілеу қажеттігін бағалау үшін маңызды құрал болып табылады.

- Жіктеу үшін екі машиналық оқыту алгоритмі қолданылды: минималды қашықтық және максималды ықтималдылық.

Минималды қашықтық алгоритмі бақылау үлгілерінің спектралдық қашықтықтарын негізге ала отырып, жаңа пикселді ең жақын орталыққа жатқызады. Бұл әдіс Евклид қашықтығын есептеу қағидасына негізделеді [8]:

$$D = \sqrt{\sum_{i=1}^n \frac{(X_j - M_{ij})^2}{S_{ij}^2}}, \quad (1)$$

мұндағы:

X_j – J-диапазонындағы X пикселінің сұр мәні;

M_{ij}, S_{ij} – I-ші j-диапазонының орташа мәні және стандартты ауытқуы;

n – спектралдық арналардың саны.

Бұл алгоритм есептеу жылдамдығы жоғары болғанымен, деректердің статистикалық таралуын есепке алмайды, сондықтан кластар арасындағы қабаттасу жағдайында төмен дәлдік көрсетуі мүмкін.

Максималды ықтималдылық – бұл Байес теоремасына негізделген бақыланатын классификация алгоритмі. Бұл алгоритм апостериорлық ықтималдықты есептеу арқылы пикселді тиісті класқа жатқызады [9]. Әдістің негізі келесі функциямен сипатталады:

²KAZ Minerals: Ақтоғай жобасы. URL: <https://www.kazminerals.com/ru/operations/aktogay/> (қаралған күні: 13.03.2025). Қолжетімділік режимі: ашық.

$$P(i|w) = \frac{P(w|i) \cdot P(i)}{P(w)}, \quad (2)$$

мұндағы:

$P(w|i)$ – ықтималдық функциясы;

$P(i)$ – априорлық ықтималдық, яғни зерттеу аймағында i класстың пайда болу ықтималдығы;

$P(w)$ – w мәнінің кездесу ықтималдығы, ол барлық кластар бойынша ықтималдықтардың қосындысы ретінде есептеледі.


- Жіктеу дәлдігін бағалау үшін жалпы дәлдік, Каппа коэффициенті, өндіруші дәлдігі және пайдаланушы дәлдігі өлшемдері қолданылды. негізгі бағалау метрикалары қолданылды.

Жалпы дәлдік – дұрыс жіктелген пикселдер санының жалпы пикселдер санына қатынасы бойынша есептеледі және жалпы классификация тиімділігін көрсетеді. Бірақ бұл көрсеткіш кездейсоқ сәйкестікті ескермейді, сондықтан Каппа коэффициенті қолданылады. Каппа – барлық кластар бойынша кездейсоқ сәйкестіктің ықтималдығын ескеретін статистикалық өлшем. Каппа коэффициенті 0-ден 1-ге дейінгі аралықта өзгереді, мұнда $\kappa > 0.81$ – өте жоғары дәлдікті, 0.61–0.80 – жоғары дәлдікті, ал 0.41–0.60 – орташа дәлдікті көрсетеді. Жеке кластар үшін өндіруші дәлдігі (белгілі бір класқа жататын пикселдердің дұрыс жіктелу көрсеткіші) және пайдаланушы дәлдігі (белгілі бір класқа жатқызылған пикселдердің шын мәнінде сол класқа тиесілігі көрсеткіші).

- Гидротермалды өзгерген аймақтарды жіктеу қорытынды нәтижелері ArcGIS Pro бағдарламалық жасақтамасында. Нәтижесінде тақырыптық карталар құрылды.

Нәтижелер мен талқылаулар

Зерттеудің алғашқы кезеңінде қызығушылық аймағы айырымдылығын бағалау анализі жүргізілді (сурет 1). Бұл талдау спектралдық тұрғыдан гидротермалды өзгерген аймақтардың айырымдылық деңгейін анықтауға және оларды әрі қарай классификациялау процесінің тиімділігін бағалауға мүмкіндік берді.




Сурет 1. Класстардың өзара айырымдылық жылу картасы.

Figure 1. Heat map of class separability.

Рис. 1. Тепловая карта разделимости классов.

Өзара айырымдылық талдау нәтижелері көрсеткендей, аргиллиттік, филлиттік және пропилиттік зоналар жоғары спектралдық айырымдылыққа ие, ал калийлік зона басқа зоналармен салыстырғанда айырымдылығы төмен екені анықталды (1.454), бұл оның спектралдық сипаттамаларының басқа класстармен қатты қабаттасатынын көрсетеді.

Келесі зерттеу кезеңінде минималды қашықтық алгоритмі қолданылды. Бұл алгоритмді пайдалана отырып жіктеу сапасының максималды дәлдігіне қол жеткізу үшін стандартты ауытқу параметрі 2 ден 8-ге дейінгі аралықта тексерілді. Сынақ нәтижелері 2-суретте бейнеленген.



Сурет 2. Минималды қашықтық алгоритмі бойынша стандартты ауытқу мәнінің өзгеруіне байланысты жалпы дәлдік динамикасы.

Figure 2. Dynamics of the overall accuracy depending on the change in the standard deviation value according to the minimum distance algorithm.

Рис. 2. Динамика общей точности в зависимости от изменения значения стандартного отклонения по алгоритму минимального расстояния.

Дәлдік талдауы стандартты ауытқу мәнінің 2-ден 6-ға дейінгі аралықта жалпы жіктеу дәлдігінің жоғарылауы байқалатынын көрсетті, жалпы дәлдік стандартты ауытқу 6 болған кезде максималды мәнге жетеді (54%). Стандартты ауытқу мәнін одан әрі арттыру керісінше, жіктеу дәлдігінің төмендеуіне алып келеді. Осылайша, жіктеу дәлдігін бағалау нәтижелері 1-кестеде көрсетілген.

Минималды қашықтық алгоритмі бойынша максималды жалпы дәлдік 54% құрады, ал Каппа коэффициенті 0.37. Сәйкесінше гидротермалды өзгерген аймақтардың картасын құру үшін (сурет 3) филлиттік (67.4%) және пропилиттік (76.01%) аймақтар таңдалды. Аргиллиттік және калийлік аймақтар төмен дәлдік көрсеткіштеріне байланысты есепке алынбады.

Максималды ықтималдылық алгоритмі бойынша нәтижелерді талдау барысында берілген 4-суретте шектік мәнінің өзгеруіне байланысты жалпы дәлдіктің (%) динамикасы көрсетілген. Бұл талдау шектік мәнінің классификация дәлдігіне әсерін анықтауға мүмкіндік береді.

Жоғарыдағы суреттен көрініп тұрғандай, шектік мән 0.05 дейін төмендеген кезде жалпы дәлдік ең жоғары деңгейге жетеді. Одан әрі мәнді төмендету (0.03 немесе 0.01) жіктеу дәлдігіне ешқандай әсер етпейді, яғни 84% деңгейінде тұрақталады. Бұл шектік мәнінің белгілі бір шекке дейін әсері бар екенін және одан төмендегенде жіктеу

Кесме 1

Минималды қашықтық бойынша жіктеу дәлдігін бағалау нәтижелері


Table 1

The results of the evaluation of classification accuracy using the minimum distance algorithm

Таблица 1

Результаты оценки точности классификации по алгоритму минимального расстояния

Гидротермалды өзгеру аймағы	Комиссия қателігі, %	Өткізіп алу қателігі, %	Өндіруші дәлдігі, %	Пайдаланушы дәлдігі, %
Аргилиттік	64.21	70.94	29.06	35.79
Филлиттік	47.79	17.20	82.80	52.03
Пропилиттік	25.76	22.22	77.78	74.24
Калийлік	40.00	73.83	26.17	60.00




Сурет 3. Минималды қашықтық алгоритмі бойынша гидротермалды өзгерген аймақтар картасы.

Figure 3. A map of hydrothermally altered areas using the minimum distance algorithm.

Рис. 3. Карта гидротермально измененных областей по алгоритму минимального расстояния.

дәлдігіне ықпал етпейтінін көрсетеді. Осылайша, максималды ықтималдылық алгоритмі негізінде гидротермалды өзгерген аймақтарды жіктеу дәлдігін бағалау нәтижелері



Сурет 4. Максималды ықтималдылық алгоритмі бойынша шектік мәнің өзгеруіне байланысты жалпы дәлдік динамикасы.

Figure 4. Dynamics of the overall accuracy depending on the change in the threshold value according to the maximum probability algorithm.

Рис. 4. Динамика общей точности в зависимости от изменения порогового значения по алгоритму максимальной вероятности.

2-кестеде ұсынылған. Бұл бағалау ең оңтайлы шектік мәнді қолдану арқылы алынған нәтижелерге негізделген. Гидротермалды өзгерген аймақтардың картасын құру үшін филлиттік, аргилиттік және пропилиттік зоналардың нәтижелері пайдаланылды (сурет 5).

Максималды ықтималдық әдісі минималды қашықтық әдісімен салыстырғанда жіктеу дәлдігін айтар-

Кесме 2

Максималды ықтималдылық бойынша жіктеу дәлдігін бағалау нәтижелері


Table 2

The results of the evaluation of the accuracy of classification using the maximum likelihood algorithm

Таблица 2

Результаты оценки точности классификации по алгоритму максимального правдоподобия

Гидротермалды өзгеру аймағы	Комиссия қателігі, %	Өткізіп алу қателігі, %	Өндіруші дәлдігі, %	Пайдаланушы дәлдігі, %
Аргилиттік	0.00	23.93	76.07	100.00
Филлиттік	17.53	13.98	86.02	82.47
Пропилиттік	2.52	7.94	92.06	97.48
Калийлік	15.75	17.45	82.55	84.25



Сурет 5. Максимальды ықтималдылық алгоритмі бойынша гидротермалды өзгерген аймақтар картасы.
Figure 5. A map of hydrothermally altered areas using the maximum likelihood algorithm.

Рис. 5. Карта гидротермально измененных областей по алгоритму максимального правдоподобия.

лықтай жақсартты, жалпы дәлдік көрсеткіші 84.12% құраса, Каппа коэффициенті 0.79 дейін артты. Орташа өндіруші дәлдігі 84.18%-ға дейін жоғарыласа, пайдаланушы дәлдігі 91.05%-ға жетті. Сонымен қатар комиссиялық және өткізіп алу қателері айтарлықтай төмендеді.

Алынған нәтижелерді талдау көрсеткендей, минималды қашықтық алгоритмі қарапайым сызықтық арақашықтық принципіне негізделгендіктен, бұл аймақтың нақты жіктеуін орындауда қиындықтарға тап болды. Бұл әсіресе спектральды айырмашылықтары аз және аралас аймақтарда маңызды фактор болып табылады.

Максимальды ықтималдық әдісі ықтималдық үлестіруді қолдану арқылы әрбір пиксельдің белгілі бір класқа жату ықтималдығын бағалайды, сондықтан ол жоғары спектральды айнымалылармен жұмыс істеуде анағұрлым тиімді болды. Осылайша, калийлік аймақтың төменгі айырымдылық көрсеткіштері және минималды қашықтық әдісінің шектеулері бұл аймақтың финалдық картаға енгізілмеуіне себеп болды. Бұл зерттеу әдісті таңдағанда аймақтың спектральды ерекшеліктерін ескерудің маңыздылығын көрсетеді.

Қорытынды

Жүргізілген зерттеу гидротермалды өзгерген аймақтарды классификациялау үшін машиналық оқыту алгоритмдерін қолданудың тиімділігін растады. Ақтоғай кен орны негізінде максимальды ықтималдық алгоритмінің минималды қашықтыққа қарағанда айтарлықтай артықшылығы көрсетілді, нәтижесінде жалпы дәлдік 84,12%-ға жетті. Бұл әдістің спектральды деректермен неғұрлым тиімді жұмыс істейтінін және кеңістіктік таралу карталарын құруда жоғары нақтылық беретінін дәлелдейді.

Болашақ зерттеулерде классификацияның дәлдігін арттыру және спектральды сипаттамалардың көптірлігін ескеру мақсатында Random Forest (RF), Support Vector Machine (SVM) және нейрондық желілер сияқты күрделі машиналық оқыту алгоритмдерін қолдану жоспарлануда. Сонымен қатар, гиперспектральды деректерді пайдалану маңызды бағыттардың бірі болып табылады, себебі олар минералдарды дәлірек анықтауға және гидротермалды өзгерген аймақтарды жіктеу сапасын жақсартуға мүмкіндік береді. Бұл тәсіл кеңістіктік деректерді өңдеу мен интерпретациялау мүмкіндіктерін кеңейтіп, геологиялық барлау үдерістерін оңтайландыруға ықпал етеді.

Алғыс

Зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитетінің қаржылық қолдауымен жүзеге асырылды (грант №BR21882179).

ПАЙДАЛАНҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Минералдарды мультиспектральды және гиперспектральды қашықтықтан зондау деректері арқылы іздеу әдістері / Ghrefat H. [және т. б.] // *Earth Observation, Geoinformatics for Geosciences*. Elsevier. 2023. Б. 197–222 (ағылшын тілінде)
2. Минералдарды мультиспектральды деректер негізінде тануға арналған машиналық оқыту әдістері / Jahoda P. [және т. б.] // *The Analyst*. 2020. Т. 146. № 1. Б. 184–195 (ағылшын тілінде)
3. SEM/EDS деректерін қолданып, өзен құмдарындағы ауыр минералдарды автоматты классификациялау үшін машиналық оқытуды қолдану / Hao H. [және т. б.] // *Minerals Engineering*. 2019. Т. 143. Б. 105899 (ағылшын тілінде)
4. Zhu G., Blumberg D.G. ASTER деректері мен SVM алгоритмін қолдана отырып жіктеу: Израильдегі Беэр-Шева мысалында // *Remote Sensing of Environment*. 2002. Т. 80. № 2. Б. 233–240 (ағылшын тілінде)
5. Patil M., Desai C., Umrikar B. Жерді пайдалану және жер жамылғысын талдауға арналған суреттерді жіктеу құралы: Максимальды ықтималдық және минималды қашықтық әдістерінің салыстырмалы зерттеуі // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLII-3/W10. Б. 605–611 (ағылшын тілінде)
6. Қазақстандағы Ақтоғай мыс-порофир кен орнының геологиясы және кен түзуші сұйықтықтардың эволюциясы / Li C. [және т. б.] // *Journal of Asian Earth Sciences*. 2018. Т. 165. Б. 192–209

(ағылшын тілінде)

7. Pons X., Cristóbal J., Sanjurjo-Vílchez J. Қашықтықтан зондтау әдебиетіндегі дивергенция және түрлендірілген дивергенция формулалары туралы ескертулер // *Remote Sensing Letters*. 2024. Т. 15. № 11. Б. 1187–1194 (ағылшын тілінде)
8. Li X., Liu L., Huang L. ENVI негізінде бірнеше қашықтықтан зондтау суреттерін жіктеу әдістерінің салыстырмалы талдауы // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLII-3/W10. Б. 605–611 (ағылшын тілінде)
9. Ahmad A., Quegan S. Мультиспектралды деректер негізіндегі максималды ықтималдық әдісін талдау // *Applied Mathematical Sciences*. 2012. Т. 6. № 129. Б. 6425–6436 (ағылшын тілінде)

REFERENCES

1. Mineral exploration using multispectral and hyperspectral remote sensing data / Ghrefat H. [et al.] // *Earth Observation, Geoinformatics for Geosciences*. Elsevier. 2023. 97–222 pp. (in English)
2. Learning for recognizing minerals from multispectral data / Jahoda P. [et al.] // *The Analyst*. 2020. V. 146. No. 1. 184–195 pp. (in English)
3. Machine learning application to automatically classify heavy minerals in river sand by using SEM/EDS data / Hao H. [et al.] // *Minerals Engineering*. 2019. V. 143. 105899 p. (in English)
4. Zhu G., Blumberg D.G. Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel // *Remote Sensing of Environment*. 2002. V. 80. No. 2. 233–240 pp. (in English)
5. Patil M., Desai C., Umrikar B. Image classification tool for land use/land cover analysis: A comparative study of maximum likelihood and minimum distance method // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLII-3/W10. 605–611 pp. (in English)
6. Geology and ore-forming fluid evolution of the Aktogai giant porphyry Cu 809 deposit, Kazakhstan / Li C. [et al.] // *Journal of Asian Earth Sciences*. 2018. V. 165. 192–209 pp. (in English)
7. Pons X., Cristóbal J., Sanjurjo-Vílchez J. Some notes on the divergence and transformed divergence formulae in the remote sensing literature // *Remote Sensing Letters*. 2024. V. 15. No. 11. 1187–1194 pp. (in English)
8. Li X., Liu L., Huang L. Comparison of several remote sensing image classification methods based on ENVI // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLII-3/W10. 605–611 pp. (in English)
9. Ahmad A., Quegan S. Analysis of maximum likelihood classification on multispectral data // *Applied mathematical sciences*. 2012. V. 6. No. 129. 6425–6436 pp. (in English)

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Минералоразведка с использованием мультиспектральных и гиперспектральных данных дистанционного зондирования / Ghrefat H. [и др.] // *Earth Observation, Geoinformatics for Geosciences*. Elsevier. 2023. С. 197–222 (на английском языке)
2. Машинное обучение для распознавания минералов по мультиспектральным данным / Jahoda P. [и др.] // *The Analyst*. 2020. Т. 146. № 1. С. 184–195 (на английском языке)
3. Применение машинного обучения для автоматической классификации тяжелых минералов в речном песке с использованием данных SEM/EDS / Hao H. [и др.] // *Minerals Engineering*. 2019. Т. 143. С. 105899 (на английском языке)
4. Zhu G., Blumberg D.G. Классификация с использованием данных ASTER и алгоритмов SVM: на примере Беэр-Шева, Израиль // *Remote Sensing of Environment*. 2002. Т. 80. № 2. С. 233–240 (на английском языке)
5. Patil M., Desai C., Umrikar B. Инструмент классификации изображений для анализа землепользования и покрова территории: сравнительное исследование метода максимального правдоподобия и метода минимального расстояния // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLII-3/W10. С. 605–611 (на английском языке)
6. Геология и эволюция рудообразующих флюидов гигантского порфирикового медного месторождения Актогай, Казахстан / Li C. [и др.] // *Journal of Asian Earth Sciences*. 2018. Т. 165. С. 192–20 (на английском языке)
7. Pons X., Cristóbal J., Sanjurjo-Vílchez J. Некоторые замечания по формулам дивергенции и преобразованной дивергенции в литературе по дистанционному зондированию // *Remote Sensing Letters*. 2024. Т. 15. № 11. С. 1187–1194 (на английском языке)
8. Li X., Liu L., Huang L. Сравнение нескольких методов классификации изображений дистанционного зондирования на основе ENVI // *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020. XLII-3/W10. С. 605–611 (на английском языке)

9. Ahmad A., Quegan S. Анализ метода максимального правдоподобия для классификации мультиспектральных данных // *Applied Mathematical Sciences*. 2012. Т. 6. № 129. С. 6425–6436 (на английском языке)

Авторлар туралы мәліметтер:

Орынбасарова Э.О., Ph.D, Геоматика инновациялық орталығының директоры, Satbayev University (Алматы қ., Қазақстан), e.orynbassarova@satbayev.university; <https://orcid.org/0000-0001-6421-4698>

Адебиет Б., Ө.А. Байқоңыров атындағы Тау-кен металлургия институтының «Маркшейдерлік іс және геодезия» кафедрасының докторанты, Satbayev University (Алматы қ., Қазақстан), 980104351171-d@stud.satbayev.university; <https://orcid.org/0009-0005-0508-018X>

Байтурбай О., з.ғ.м., Ө.А. Байқоңыров атындағы Тау-кен металлургия институтының Маркшейдерлік іс және геодезия кафедрасының ассистенті, Satbayev University (Алматы қ., Қазақстан), o.baiturbay@satbayev.university; <https://orcid.org/0000-0002-7654-2610>

Закария М.К., Ph.D, К. Тұрысов атындағы геология және мұнай-газ ісі институтының «Мұнай-газ және кен геофизикасы» кафедрасының оқытушысы, Satbayev University (Алматы қ., Қазақстан), zakariya.maksat@gmail.com; <https://orcid.org/0009-0002-6971-9710>

Information about the authors:

Orynbassarova E.O., Ph.D, Associate Professor, Director of the Geomatics Innovation Center, Satbayev University (Almaty, Kazakhstan)

Adebiyet B., Ph.D student at the Department of SaG, of the Mining and Metallurgical Institute named after O.A. Baikonurov of the Satbayev University (Almaty, Kazakhstan)

Baiturbay O., Master of Law, Assistant at the Department of SaG, Mining and Metallurgical Institute named after O.A. Baikonurov, Satbayev University (Almaty, Kazakhstan)

Zakariya M.K., Ph.D Doctor, Lecturer at the Department of «Oil and Ore Geophysics» of the K. Turysov Institute of Geology and Oil and Gas Business, Satbayev University (Almaty, Kazakhstan)

Сведения об авторах:

Орынбасарова Э.О., Ph.D, директор Инновационного центра геоматики, Satbayev University (г. Алматы, Казахстан)

Адебиет Б., докторант кафедры «Маркшейдерское дело и геодезия» Горно-металлургического института им. О.А. Байконурова, Satbayev University (г. Алматы, Казахстан)

Байтурбай О., м.ю.н., ассистент кафедры МДиГ Горно-металлургического института О.А. Байконурова, Satbayev University (г. Алматы, Казахстан)

Закария М.К., доктор Ph.D кафедры «Нефтегазовая и рудная геофизика» института геологии и нефтегазового дела имени К. Турысова, Satbayev University (г. Алматы, Казахстан)



TECH MINING RUSSIA

www.techmining.ru

7-Я СПЕЦИАЛИЗИРОВАННАЯ КОНФЕРЕНЦИЯ И ВЫСТАВКА

СТРОИТЕЛЬСТВО, МОДЕРНИЗАЦИЯ И ЦИФРОВИЗАЦИЯ ГОРНОГО ПРЕДПРИЯТИЯ

17-18

сентября
2025

Москва

Novotel Moscow City



16+

