



УДК 902.904 (574)
МРНТИ 03.41.91

<https://doi.org/10.52967/akz2026.1.31.290.310>

Выявление курганов в регионе Жетысу (Казахстан) на основе спутниковых изображений и методов глубинного обучения (Deep Learning)

© 2026 г. Ким Ёнхён

Keywords: Deep Learning, Jetisu, kurgan, Semantic Segmentation, Temporal Generalization

Түйін сөздер: терең оқыту, Жетісу, оба, семантикалық сегментация, уақыт бойынша жалпылау

Ключевые слова: глубинное обучение, Жетысу, курган, семантическая сегментация, временная обобщаемость

Younghyun Kim¹

¹Ph.D. Student, Korea National University of Heritage, Buyeo, Republic of Korea.
ORCID [0009-0004-2241-3727](https://orcid.org/0009-0004-2241-3727) E-mail: yesimok@mail.ru

Detection of Kurgans in the Jetisu Region (Kazakhstan) Based on Satellite Imagery and Deep Learning Methods

This study proposes a methodology for the automatic detection of kurgans in the semi-desert steppe environment of the Jetisu region (southeastern Kazakhstan) using time series of multispectral Sentinel-2 imagery and semantic segmentation based on a U-Net architecture. Monthly Sentinel-2 Level-2A composite images for the period from April 2021 to July 2025 were generated in Google Earth Engine, reducing the impact of cloud cover and seasonal variability in acquisition conditions. As input data, six spectral bands were used, resampled to a spatial resolution of 10 m and spatially aligned within a base area of interest. Reference labels were produced by manual digitization of kurgans followed by rasterization, and a binary mask was used for model training. The experimental design relies on a strict temporal split: 2021–2023 for training, 2024 for validation, and 2025 as a fully independent test set to assess temporal generalization. On the fully independent Sentinel-2 test set for 2025, the baseline configuration (R2) achieved Precision = 0.49 and Recall = 0.86, reflecting a detection strategy that prioritizes sensitivity and minimizes misses (FN) at the expense of increased false-positive responses. Under an extremely sparse positive class, such a balance is consistent with archaeological reconnaissance, where missing a potential feature is more critical than subsequent expert filtering.

For citation: Kim, Younghyun. 2026. Detection of Kurgans in the Jetisu Region (Kazakhstan) Based on Satellite Imagery and Deep Learning Methods. *Kazakhstan Archaeology* 1 (31), 290–310 (in Russian). DOI: [10.52967/akz2026.1.31.290.310](https://doi.org/10.52967/akz2026.1.31.290.310)

Ёнхён Ким¹

¹Докторант, Корея ұлттық мұра университеті,
Пуё қ., Корея Республикасы

Спутниктік суреттер мен терең оқыту (Deep Learning) әдістері негізінде Жетісу (Қазақстан) өңіріндегі обаларды анықтау

Бұл зерттеуде Sentinel-2 көп спектрлі спутниктік суреттердің уақыттық қатарлары мен U-Net архитектурасын қолдана отырып, семантикалық сегментациялау негізінде Жетісу (Қазақстанның оңтүстік-шығысы) өңірінің шөлейтті дала жағдайында обаларды автоматты түрде анықтауға арналған әдістеме ұсынылады. Google Earth Engine ортасында 2021 жылдың сәуірі мен 2025 жылдың шілдесі аралығындағы кезеңді қамтитын Sentinel-2 Level-2A айлық композиттік суреттері құрастырылды, бұл бұлттылықтың әсерін және түсірілім жағдайларының маусымдық өзгергіштігін төмендетуге мүмкіндік берді. Кіріс деректері ретінде 10 м кеңістіктік ажыратымдылыққа келтірілген және негізгі талдау аймағының шегінде сәйкестендірілген алты спектрлік арна пайдаланылды. Эталондық таңбалау обаларды қолмен цифрлау, кейіннен растрлау арқылы жасалды,



ал модельді оқыту үшін бинарлық маска қолданылды. Эксперименттік дизайн деректерді уақыт бойынша қатаң бөлуге негізделген: 2021–2023 жж. – оқыту, 2024 ж. – валидация, 2025 ж. – уақытша жалпылауды бағалауға арналған толық тәуелсіз сынақ. 2025 жылғы Sentinel-2 толық тәуелсіз сынақ жиынтығында базалық конфигурация (R2) Precision = 0,49 және Recall = 0,86 көрсеткіштерін көрсетті. Бұл жалған теріс нәтижелерді (FN) азайту және сезімталдықты арттыруға бағытталған, бірақ жалған оң (false positive) нәтижелердің көбеюіне әкелетін анықтау стратегиясын көрсетеді. Оң класс аса сирек болған жағдайда мұндай тепе-теңдік археологиялық барлаудың мақсаттарына сай келеді, өйткені ықтимал нысанды жіберіп алу кейінгі сараптамалық сүзгіден гөрі анағұрлым маңызды.

Сілтеме үшін: Ким Ёнхён. Спутниктік суреттер мен терең оқыту (Deep Learning) әдістері негізінде Жетысу (Қазақстан) өңіріндегі обаларды анықтау. *Қазақстан археологиясы*. 2026. № 1 (31). 290–310-бб. (Орысша).

Ёнхён Ким¹

¹Докторант, Корейский национальный университет наследия,
г. Пуё, Республика Корея

Выявление курганов в регионе Жетысу (Казахстан) на основе спутниковых изображений и методов глубинного обучения (Deep Learning)

В настоящем исследовании предлагается методология автоматического выявления курганов в полупустынной степной среде региона Жетысу (юго-восток Казахстана) на основе временных рядов многоспектральных спутниковых изображений Sentinel-2 и семантической сегментации с использованием архитектуры U-Net. Месячные композитные изображения Sentinel-2 Level-2A за период с апреля 2021 г. по июль 2025 г. были сформированы в среде Google Earth Engine, что позволило снизить влияние облачности и сезонной вариабельности условий съёмки. В качестве входных данных использовались шесть спектральных каналов, приведённых к пространственному разрешению 10 м и согласованных в пределах базовой области анализа. Эталонная разметка была создана путём ручной оцифровки курганов с последующей растровизацией и применением бинарной маски для обучения модели. Экспериментальный дизайн основан на строгом временном разделении данных: 2021–2023 гг. – обучение, 2024 г. – валидация, 2025 г. – полностью независимое тестирование для оценки временной обобщаемости. На полностью независимом тестовом наборе Sentinel-2 за 2025 г. базовая конфигурация (R2) достигла Precision = 0,49 и Recall = 0,86, что отражает стратегию обнаружения, ориентированную на повышение чувствительности и минимизацию пропусков (FN) ценой увеличения ложноположительных откликов. В условиях крайне разреженного положительного класса такой баланс соответствует задаче археологической разведки, где пропуск потенциального объекта более критичен, чем последующая экспертная фильтрация.

Для цитирования: Ким Ёнхён. Выявление курганов в регионе Жетысу (Казахстан) на основе спутниковых изображений и методов глубинного обучения (Deep Learning). *Археология Казахстана*. 2026. № 1 (31). С. 290–310.

1 Введение

Изучение пространственного распределения курганов в Центральной Азии имеет ключевое значение для реконструкции пространственной организации древних обществ. Однако традиционные археологические методы, включая наземные обследования и визуальную интерпретацию спутниковых изображений, характеризуются высокой трудоёмкостью и ограниченной масштабируемостью, особенно в труднодоступных регионах. Развитие спутникового дистанционного зондирования и методов глубинного обучения (Deep Learning) открыло новые возможности для автоматизации археологического поиска, однако нечёткость морфологических признаков курганов и сложный фоновый контекст по-прежнему затрудняют их надёжное выявление.

Автоматизированная детекция археологических насыпей на основе данных дистанционного зондирования развивается по нескольким взаимодополняющимся направлениям. Во-первых, мультисенсорные и мультивременные исследования продемонстрировали потенциал масштабного картирования насыпей на региональном уровне. Orengo et al. [2020] использовали мультисенсорный подход (радиолокационные данные (SAR) и мультиспектральные данные) в среде Google Earth



Engine (GEE) для автоматизированной вероятностной классификации археологических насыпей на региональном уровне. Валидация выполнялась с применением пространственного разделения выборки, что позволило оценить устойчивость модели в пределах изучаемой территории. Однако строгая временная независимость тестирования не являлась центральным элементом экспериментального дизайна. Berganzo-Besga et al. [2021] реализовали гибридный алгоритм, объединяющий мультитременные данные Sentinel-2 и морфометрические признаки LiDAR (Light Detection and Ranging), что позволило автоматически выявить около 10 000 курганов. Оценка качества проводилась на основе случайного разделения данных и анализа показателей точности и полноты (Precision, Recall) с акцентом на контроль ложноположительных срабатываний при крупномасштабном картировании.

Во-вторых, значительное направление связано с использованием данных LiDAR и цифровых моделей рельефа. Guyot et al. [2018] предложили многошкальный морфометрический анализ для выявления неолитических насыпей, показав преимущество высокодетализированных DEM (Digital Elevation Model) при изучении микрорельефа. Trier et al. [2021] и Verschoof-van der Vaart & Lambers [2019] продемонстрировали эффективность сверточных нейронных сетей (Convolutional Neural Networks; CNN), включая Faster R-CNN для автоматизированного картирования объектов культурного наследия на основе LiDAR. Meyer-Heß et al. [2022] дополнительно исследовали пространственные взаимосвязи археологических структур с применением глубоких нейронных сетей на DEM.

В-третьих, развиваются подходы, основанные на оптических изображениях высокого разрешения. Caspari & Crespo [2019] применили сверточные нейронные сети для поиска элитных погребений на основе оптических изображений высокого пространственного разрешения. Исследование носило целенаправленный характер и было ориентировано на детекцию отдельных элитных погребений, а не на масштабное региональное картирование при среднем разрешении. Koziol et al. [2025] показали, что даже данные среднего пространственного разрешения (Sentinel-2) могут использоваться для выявления погребальных структур при интеграции спектральных и вспомогательных факторов.

Наконец, в последние годы усиливается внимание к вопросам воспроизводимости и стандартизации. Kokalj et al. [2023] представили аннотированный набор данных, подготовленный для задач машинного обучения (ML-ready), включающий Sentinel-1/2 и другие источники, с целью стандартизации протоколов обучения и оценки. Работа ориентирована на повышение воспроизводимости и сопоставимости экспериментов в археологической детекции. Jakubczak et al. [2024] подробно рассмотрели методологические ограничения автоматической детекции, включая вопросы разметки и валидности результатов. Прикладные инициативы, такие как технический отчет Kramer [2023], свидетельствуют о растущем внедрении ИИ-подходов в археологическую практику.

Несмотря на значительный прогресс, в большинстве исследований схема валидации основана на пространственном или случайном разделении выборки. При использовании мультитременных данных такой подход может приводить к частичной утечке информации между обучением и тестированием. Строго временно независимое тестирование применяется сравнительно редко, особенно в исследованиях, ориентированных на спутниковые данные среднего пространственного разрешения (10 м). Кроме того, в ряде работ основной акцент делается на достижении высоких формальных метрик – общей точности классификации (Accuracy), тогда как интерпретация вероятностных карт как археологически значимых пространственных сигналов рассматривается ограниченно. В этой связи возникает необходимость в строго формализованной временно независимой схеме тестирования, ориентированной на оценку реальной межгодовой переносимости модели.

Таблица 1 – Методологическое сопоставление аналогичных исследований
1-кесте – Ұқсас зерттеулерді әдістемелік тұрғыдан салыстыру
Table 1 – Methodological comparison of analogous studies

Исследование	Сенсор	Пространственное разрешение	Масштаб анализа	Схема валидации	Метрики	Практическая направленность
Orengo et al., 2020	Мультисенсорные данные (оптические + радарные)	10–30 м	Крупномасштабный региональный анализ	Кросс-валидация	Accuracy	Картирование на больших территориях
Berganzo-Besga et al., 2021	Sentinel-2 + вспомогательные данные	10 м	~ 10 000 насыпных объектов	Случайное разделение	Precision, Recall	Контроль ложных срабатываний
Caspari & Crespo, 2019	Оптические изображения высокого разрешения	Высокое	Целенаправленный поиск	Кейсовый анализ	Recall, Precision (задача обнаружения)	Поиск элитных погребений
Kokalj et al., 2023	Sentinel-1/2, LiDAR и др.	Много-масштабное	Публикация дата сета	Стандартное ML-разделение	Стандартные ML-метрики	Воспроизводимость
Настоящее исследование	Sentinel-2 (временные ряды)	10 м	Базовая контролируемая АОІ	Строгое временное разделение (2021–2025)	IoU, F1; Объектный IoU $\geq 0,1$	Временная обобщаемость и археологическая интерпретация

Как показано в таблице 1, настоящее исследование использует исключительно данные Sentinel-2 (10 м) и строгую временно независимую схему 2021–2023 / 2024 / 2025, ориентированную на оценку временной обобщаемости. Выход модели трактуется как вероятностная разведочная информация для пространственного ранжирования, а качество описывается двуровневым протоколом (пиксельный/объектный). На пиксельном уровне использованы коэффициент пересечения по объединению (Intersection over Union; IoU) и F1-мера, а на объектном уровне – объектный IoU с порогом 0,1. В условиях полупустынной среды Жетысу это позволяет сопоставимо интерпретировать результаты без привлечения дополнительных сенсоров. Вклад настоящего исследования заключается в следующем:

- (1) применение строго формализованного временного разделения данных (2021–2023 – обучение, 2024 – валидация, 2025 – независимый тест);
- (2) сочетание пиксельной и объектно-ориентированной оценки с явной формализацией критериев перекрытия;
- (3) интерпретация выходных вероятностных карт как разведочной информации для пространственного ранжирования кандидатных зон;
- (4) эмпирическое тестирование методики в полупустынной степной среде с выраженной сезонной вариабельностью, характерной для региона Жетысу.



2 Район исследования и аналитические рамки

2.1 Характеристика района Жетысу и курганного ландшафта

Район исследования охватывает полупустынную степную зону региона Жетысу, расположенного на юго-востоке Казахстана (рис. 1)*. (*Иллюстрации подготовлены автором). Данный регион является одним из ключевых археологических районов Центральной Азии, где курганы различных эпох – от бронзового века до раннего железного века и более поздних периодов – представлены в высокой концентрации и формируют протяжённую пространственную сеть.

В геоморфологическом отношении территория характеризуется сочетанием пологих холмов, гребневых участков, склонов и относительно ровных степных поверхностей. Общие перепады высот невелики, однако микрорельефные изменения проявляются непрерывно на значительных площадях. Растительный покров преимущественно разреженный, при этом сезонные колебания температуры и осадков приводят к заметной вариабельности состояния травянистой растительности и почвенной влажности.

С точки зрения анализа спутниковых изображений данная среда обладает двойственным характером. Относительно однородный фон по сравнению с лесными или интенсивно освоенными территориями облегчает выявление слабых поверхностных различий. Одновременно сезонная динамика растительности и почвенной влаги проявляется как в окрестностях курганов, так и в окружающем ландшафте в целом, что затрудняет их спектральное разграничение от природных форм рельефа.

При разрешении Sentinel-2 (10 м) курганы обычно не формируют чётких геометрических контуров и проявляются как пространственные паттерны, включающие насыпь и прилегающие зоны слабых поверхностных откликов.

2.2 Обоснование выбора базовой АОI и границы анализа

Для обеспечения корректного обучения и объективной оценки модели в исследовании была выделена базовая область интереса (Area of Interest; АОI), далее – базовая АОI, включающая участки с ранее подтверждённым наличием курганов. Такой выбор позволил сформировать надёжные эталонные данные (Ground Truth; GT), необходимые для интерпретации выходных результатов модели.

Определение базовой АОI является методологическим решением, направленным на анализ того, каким образом модель глубинного обучения усваивает курган как археологический пространственный объект. На основе вручную оцифрованных векторных данных курганов в пределах базовой АОI была сформирована эталонная маска, единообразно использованная на этапах обучения, валидации и тестирования. Это обеспечило сопоставимость результатов и позволило сосредоточиться на анализе базовых свойств модели, включая её временную обобщаемость.

При этом настоящее исследование не ставит целью немедленное широкомасштабное применение модели ко всей территории региона Жетысу. Базовая АОI рассматривается как опорная аналитическая рамка и исходная точка для последующего поэтапного расширения анализа и переноса модели на более обширные пространства. Таким образом, работа ориентирована на формирование методологического фундамента для дальнейших исследований, а не на демонстрацию финальных результатов автоматического поиска.

3 Получение и предварительная обработка данных Sentinel-2

В настоящем исследовании использовались многоспектральные спутниковые изображения Sentinel-2 уровня обработки Level-2A, полученные с применением платформы GEE. Пространственное разрешение данных Sentinel-2 (10–20 м) ограничивает прямое распознавание точных контуров




Рис. 1. Расположение района исследования: общий вид территории по данным ©Google Earth с выделением границ исследуемой области и вставкой композитного изображения, полученного в среде GEE

1-сур. Зерттеу ауданының орналасуы: зерттеу аймағы шекараларының белгіленуі және GEE кеңістігінде алынған композиттік суреттің кіріктірілуі көрсетілген ©Google Earth деректері бойынша аумақтың жалпы көрінісі

Fig. 1. Location of the study area: overview of the territory based on ©Google Earth imagery, showing the boundaries of the study area and an inset composite image generated in GEE

малых археологических объектов, однако позволяет эффективно фиксировать косвенные спектральные признаки, связанные с микрорельефом, растительным покровом и состоянием почвы в окрестностях курганов. Такой подход соответствует цели исследования, в рамках которой курганы рассматриваются не как чётко ограниченные объекты, а как пространственные паттерны, формирующиеся во взаимодействии с окружающей средой.

Период сбора данных охватывает апрель 2021 г. – июль 2025 г. Для снижения влияния облачности и различий условий съёмки применялась процедура месячной компоновки изображений на основе валидных пикселей после маскирования облаков. Для каждого месяца формировался ежемесячный композит по медиане пикселям (SCL вне классов 3 и 8–11, то есть исключены тени, облака и их проекции, а также снег/лёд) при условии облачности < 20%, что повышало сопоставимость временных срезов.

Всего сформировано 52 ежемесячных композита (2021–2025), используемых в строгой временной схеме разделения (табл. 2). В качестве входных данных использовались шесть спектральных каналов Sentinel-2 (B2, B3, B4, B8, B8A, B11). Каналы с исходным пространственным разрешением 20 м (B8A, B11) были приведены к 10 м методом билинейной интерполяции для обеспечения пиксельной согласованности. Все изображения были приведены к единому пространственному охвату базовая АОИ и системе координат EPSG:32644 и экспортированы в

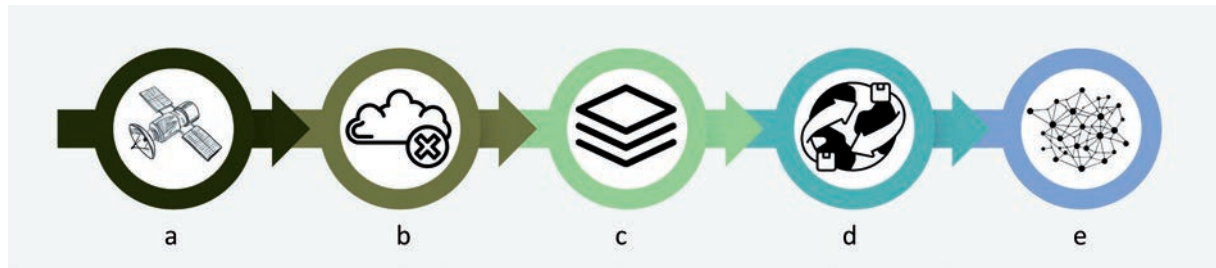


Рис. 2. Пайплайн предварительной обработки изображений Sentinel-2 и формирования входных данных: (а) получение изображений Sentinel-2 L2A в среде Google Earth Engine (GEE); (b) облачная маска для удаления облаков и облачных теней; (с) формирование месячного композитного изображения; (d) экспорт данных в формате GeoTIFF в системе координат EPSG:32644; (е) подготовка данных, используемых в качестве входных для модели глубокого обучения

2-сур. Sentinel-2 суреттерін алдын ала өңдеу және кіріс деректерін қалыптастыру пайплайны: (а) Google Earth Engine (GEE) ортасында Sentinel-2 L2A суреттерін алу; (b) бұлттар мен олардың көлеңкелерін жоюға арналған бұлттылық маскасы; (с) бір айлық композиттік суретті қалыптастыру; (d) EPSG:32644 координаттар жүйесіндегі деректерді GeoTIFF форматына экспорттау; (е) терең оқыту моделі үшін кіріс деректер ретінде пайдаланылатын деректерді дайындау

Fig. 2. Preprocessing pipeline for Sentinel-2 imagery and preparation of input data: (a) acquisition of Sentinel-2 L2A imagery in Google Earth Engine (GEE); (b) cloud masking to remove clouds and cloud shadows; (c) generation of monthly composite imagery; (d) export to GeoTIFF format in the EPSG:32644 coordinate system; (e) preparation of data used as input to the deep learning model




Рис. 3. Сезонные визуальные различия во временном ряду изображений Sentinel-2: (1) весна; (2) лето; (3) осень; (4) зима

3-сур. Sentinel-2 суреттерінің уақыттық қатарындағы маусымдық визуалды айырмашылықтар: (1) көктем; (2) жаз; (3) күз; (4) қыс

Fig. 3. Seasonal visual differences in the Sentinel-2 image time series: (1) spring; (2) summer; (3) autumn; (4) winter



формате GeoTIFF с масштабом 10 м, что обеспечило пространственную согласованность временных срезов и корректность анализа спектральных изменений во времени.

Все каналы применялись в виде исходных значений отражательной способности без расчёта производных индексов (например, NDVI), что позволило модели самостоятельно усваивать информативные спектральные сочетания. На этапе обучения значения отражательной способности ограничивались сверху значением 4000, после чего масштабировались делением на 4000. Такая схема нормализации снижала влияние выбросов и стабилизировала распределения значений между сезонами и годами.

Таблица 2 – Состав временного ряда изображений Sentinel-2
2-кесте – Sentinel-2 суреттерінің уақыттық қатарларының құрамы
Table 2 – Composition of the Sentinel-2 image time series

Год	Назначение	Количество изображений
2021	Обучение	9
2022–2023	Обучение	24
2024	Валидация	12
2025	Тестирование	7
Итого:		52

4 Формирование эталонной разметки

Эталонная разметка в настоящем исследовании была сформирована как ключевое связующее звено между археологической интерпретацией курганов и анализом спутниковых изображений методами глубинного обучения. Приоритет был отдан надежности археологической идентификации, а не количественному увеличению обучающих данных; объекты с неопределённым или дискуссионным статусом были исключены из эталонного набора.

Основой для формирования эталонной разметки послужили векторные данные курганов, вручную оцифрованные в пределах базовой АОІ. Разметка выполнялась с опорой на результаты предыдущих археологических исследований, визуальную интерпретацию высокоразрешённых спутниковых изображений и анализ рельефа. При определении границ курганов учитывались форма насыпей, относительные высотные различия и особенности распределения растительности. Использование векторного формата позволило сохранить единые археологические критерии описания курганов, независимые от пространственного разрешения спутниковых данных.

Векторные данные были преобразованы в растровый формат с пространственным разрешением 10 м и системой координат EPSG:32644, полностью согласованными с входными изображениями Sentinel-2. В процессе растровизации детальные контуры курганов неизбежно упрощались, что рассматривается не как потеря информации, а как адаптация археологической интерпретации к физическим ограничениям спутниковых данных.

Растровая эталонная разметка сохранялась в виде ID-маски, в которой каждому кургану соответствовал уникальный идентификатор. На этапе обучения использовалась её бинарная версия (ID>0), что позволило сформулировать задачу как семантическую сегментацию, ориентированную на различение пространств с наличием курганов и фоновой поверхности.




Рис. 4. Результаты построения векторных данных курганов (1) и результаты растровизации эталонной маски курганов (2)
4-сур. Обалардың векторлық деректерін құру нәтижелері (1) және обалардың эталондық маскасын растрлау нәтижелері (2)

Fig. 4. Results of kurgan vector data generation (1) and rasterization of the reference kurgan mask (2)

5 Архитектура модели и стратегия обучения

5.1 Архитектура модели и входные данные

Для задачи выявления курганов использовалась архитектура U-Net, ориентированная на бинарную семантическую сегментацию. Энкодер-декодерная структура U-Net позволяет учитывать одновременно глобальный контекст сцены и локальные пространственные признаки, что важно для археологических объектов с размытыми границами и слабой контрастностью.

В качестве энкодера применялась ResNet-34 с весами, предварительно обученными на наборе данных ImageNet, что обеспечивало более стабильную инициализацию признаков и ускоряло сходимость при ограниченном объеме обучающих данных.

Входные данные представляли собой шестиканальные тензоры из спектральных каналов Sentinel-2. Выход модели формировался в виде карты логитов, отражающей вероятность принадлежности каждого пикселя к классу «курган». Выходная активация не применялась, поскольку вычисление функции потерь выполнялось на логитах, что повышает численную устойчивость.



5.2 Стратегия обучения и формирование датасета

Для проверки временной обобщаемости использовалась стратегия строгого временного разделения данных. Месячные изображения Sentinel-2 за 2021–2023 гг. применялись для обучения, данные за 2024 г. – для валидации, а изображения за январь – июль 2025 г. полностью исключались из процессов обучения и валидации и использовались в качестве независимого тестового набора. Такая схема исключает временную утечку информации (temporal leakage) и обеспечивает оценку способности модели к обобщению на будущие данные.

Для формирования входных данных использовался метод скользящего окна с разбиением изображений на тайлы размерами 128×128 пикселей и шагом 64 пикселя, что обеспечивало 50% перекрытие. Параметры тайлинга фиксировались и не изменялись между экспериментальными прогонами; это гарантирует воспроизводимость и снижает потери информации, когда курганы попадают вблизи границ тайлов.




Рис. 5. (1) Концепция тайлинга изображений с использованием скользящего окна: (а) изображение Sentinel-2 в пределах базовой области интереса (AOI); (б) применение скользящего окна (перекрытие 50%); (с) формирование патчей размерами 128×128 пикселей; (д) пример полученного патча (stride 64, перекрытие 50%); (2) Концептуальная схема оценки на разных уровнях (красный круг – пиксель, синий круг – объект, зелёный прямоугольник – тайл)

5-сур. (1) Жылжымалы терезе әдісін қолдану арқылы суреттерді тайлингтеу тұжырымдамасы: (а) негізгі зерттеу аймағы (AOI) шегіндегі Sentinel-2 суреті; (б) жылжымалы терезені қолдану (қамту 50%); (с) өлшемі 128×128 пиксель болатын патчтарды қалыптастыру; (д) алынған патчтың үлгісі (stride 64, қамту 50%); (2) Әртүрлі деңгейлердегі бағалаудың тұжырымдамалық схемасы (қызыл шеңбер – пиксель, көк шеңбер – нысан, жасыл тіктөртбұрыш – тайл)

Fig. 5. (1) Concept of image tiling using a sliding-window approach: (a) Sentinel-2 image within the base AOI; (b) sliding window (50% overlap); (c) 128×128 patch generation; (d) example patch (stride 64, 50% overlap); (2) Conceptual diagram of evaluation at different levels (red circle – pixel, blue circle – object, green rectangle – tile)

5.2.1 Обоснование морфологического расширения (dilation) как операционной погрешности ($r_{dil} = 0-3$)

С учётом пространственного разрешения Sentinel-2 (10 м) отдельные курганы в пределах исследуемой территории могут быть представлены всего 1–2 пикселями. В условиях крайне разреженного положительного класса такая дискретизация увеличивает вероятность пропуска малых объектов при обучении и повышает чувствительность к небольшим геометрическим несоответствиям между снимком и разметкой.



Морфологическое расширение вводится как операционное допущение для обучения при 10-м разрешении и не применяется при финальной оценке, что исключает изменение эталона. Расширение радиусом r применялось исключительно на этапе обучения к бинарной маске ($ID > 0$) и не применялось при финальной оценке на независимом тестовом наборе 2025 г., где сохранялась исходная ID-маска без расширения. Это исключает риск завышения качества за счёт изменения эталона.

Для оценки влияния параметра морфологического расширения был проведён анализ чувствительности ($r_dil = 0-3$). Для каждого значения радиуса модель обучалась при неизменной архитектуре, параметрах оптимизации, временной схеме разделения данных и тайлинге. При $r_dil = 0$ наблюдаются пропуски минимальных объектов, что снижает объектную полноту. При $r_dil = 1$ полнота максимальна, но возрастает положительная площадь предсказаний и нагрузка на интерпретацию. При $r_dil = 2$ достигается устойчивый компромисс между объектной полнотой и контролируемой структурой связных компонент. При $r_dil = 3$ положительная область расширяется дальше и компоненты укрупняются, увеличивая объём последующей проверки (табл. 3).

*Таблица 3 – Анализ чувствительности радиуса морфологического расширения ($r_dil = 0-3$)
3-кесте – Морфологиялық кеңейту радиусына ($r_dil = 0-3$) қатысты сезімталдықты талдау
Table 3 – Sensitivity analysis of the morphological dilation radius ($r_dril = 0-3$)*

R	TP_rate	Positive area ratio	FP cluster ratio	$r_dil \times 10$ (м)
0	0,735417	0,002125	0,016949	0
1	0,997917	0,009684	0,043062	10
2	0,972917	0,021656	0,237500	20
3	1,000000	0,036940	0,180328	30

TP_rate отражает долю обнаруженных объектов относительно исходной ID-маски на независимом тесте 2025 г. Positive area ratio соответствует доле пикселей, предсказанных как положительные при пороге $t = 0,5$. FP cluster ratio показывает долю связных компонент предсказания, не имеющих пересечения с эталонной маской. Эффективная допустимая погрешность (effective tolerance) интерпретируется как $r_dil \times 10$ м при пространственном разрешении 10 м (Sentinel-2).

5.2.2 Дисбаланс классов и отбор фоновых тайлов (formalization)

Определение пустого-тайла: тайл считается пустым, если в бинарной маске $pos_pixels = 0$ (все пиксели имеют $ID = 0$). Доли пустых-тайлов при тайлинге $128 \times 128 / шаг 64$ пикселя: train 9/2220 (0,41%), val 36/840 (4,29%), test 21/490 (4,29%). Низкая доля в train обусловлена естественным пространственным распределением, а не агрессивным удалением фона. Любые операции по изменению доли фона применяются только к train. Разбиение тайлов фиксируется в dataset_manifest.csv (SSOT – Single Source Of Truth); стохастические компоненты фиксируются при $seed = 42$.

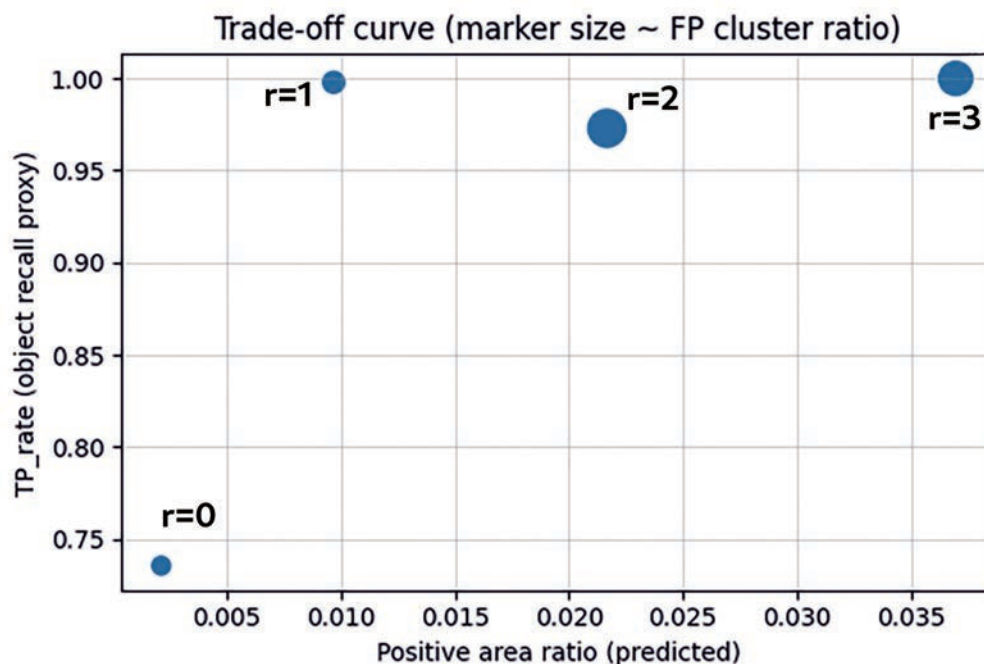


Рис. 6. Баланс между объектной полнотой и пространственным расширением предсказаний при различных радиусах морфологического расширения
6-сур. Морфологиялық кеңейтудің әртүрлі радиустарындағы объектілердің толық болуы мен болжамдардың кеңістіктік кеңеюі арасындағы теңгерім
Fig. 6. Trade-off between object completeness and spatial expansion of predictions at different morphological dilation radii

5.2.3 Сравнение с классическими ML-бейзлайнами (тайл-уровень)

Таблица 4 – Сравнение U-Net и классических ML-бейзлайнов на независимом тесте 2025 г.
4-кесте – 2025 ж. тәуелсіз сынақта U-Net пен классикалық ML-бейзлайндарын салыстыру
Table 4 – Comparison of U-Net and classical ML baselines on the 2025 test set

Модель	Уровень оценки	Balanced Accuracy	Precision	Recall	F1	AUC
U-Net(R2)	Пиксельный	-	0,490	0,860	-	-
Random Forest(K=32)	Тайл (128 × 128)	0,671	0,946	0,913	0,930	0,759
Logistic Regression (K = 32)	Тайл (128 × 128)	0,652	0,944	0,874	0,908	0,633

В рамках сопоставления были построены классические ML-бейзлайны (Random Forest и Logistic Regression), обученные на агрегированных статистических признаках, извлечённых из тех же тайлов Sentinel-2 (шесть спектральных каналов, 128×128 пикселей). В качестве признаков использовались средние значения и стандартные отклонения спектральных каналов. Для всех



моделей применялись идентичные временные разбиения данных (2021–2023 – обучение; 2024 – валидация; 2025 – независимое тестирование), что обеспечивало корректность прямого сравнения.

В качестве положительного класса использовано операционное определение $k = 32$: тайл считался положительным при наличии ≥ 32 положительных пикселей, отрицательным – при их отсутствии. Random Forest продемонстрировал более высокие показатели (balanced accuracy = 0,671; AUC = 0,759) по сравнению с Logistic Regression (0,652/0,633). Однако оба подхода основаны на агрегированных статистических признаках и не способны непосредственно учитывать пространственную структуру и контекст внутри изображения.

Сегментационная модель U-Net, напротив, опирается на пиксельный пространственный контекст и на независимом тесте 2025 г. демонстрирует высокую полноту обнаружения (Recall = 0,860), что принципиально важно для задач археологической разведки, ориентированной на минимизацию пропусков потенциальных объектов.

Несмотря на высокие сводные метрики на тайл-уровне, эти модели не формируют пространственно непрерывные вероятностные карты и не поддерживают объектную интерпретацию. Поэтому U-Net остаётся более согласованным с задачей ранжирования и картографирования.

5.3 Протокол оценки качества: пиксельный и объектный уровни

Объектный уровень. Исходная ID-маска рассматривается как набор $K = 480$ объектов. Для каждого объекта формируется буферная зона радиуса $r_{obj} = 2$ пикселя (≈ 20 м) вокруг центрального seed-пикселя.

Бинаризованное предсказание ($t = 0,5$) сопоставляется с буферной зоной объекта. Степень перекрытия оценивается с использованием метрики IoU:

$$IoU = \frac{|P \cap G|}{|P \cup G|},$$

где P – множество положительных пикселей предсказания, G – буферизованная область эталонного объекта.

Классификация объектов выполняется следующим образом:

- верно обнаружено (TP), если $IoU \geq \tau$, где $\tau = 0,1$;
- частичное совпадение (mismatch), если $|P \cap G| > 0$, но $IoU < \tau$;
- пропуск (FN), если $|P \cap G| = 0$.

Порог $\tau = 0,1$ используется для отделения случайного касания от пространственно согласованного обнаружения.

Дополнительно учитывается доля положительной площади предсказания (pred_pos_ratio) как индикатор объёма последующей проверки.

Таблица 5 – Сравнение стратегий преодоления дисбаланса классов на независимом тесте 2025 г.: пиксельные (IoU, F1, Precision, Recall) и объектные (TP, mismatch, FN) показатели 5-кесте – 2025 ж. тәуелсіз сынақта кластар теңгерімсіздігін еңсеру стратегияларын салыстыру: пиксель (IoU, F1, Precision, Recall) және объект (TP, mismatch, FN) көрсеткіштері
Table 5 – Comparison of class-imbalance mitigation strategies on the 2025 test set: pixel-level metrics (IoU, F1, Precision, Recall) and object-level metrics (TP, mismatch, FN)

Run tag	Empty retention	Loss	Pos_weight	Test IoU	Test F1	Object TP
R0_E100_bce_dice	E100	BCE+Dice	-	0,6034	0,7527	218
R1_E100_bce	E100	BCE	-	0,6664	0,7998	367
R2_E100_wbce	E100	Weighted BCE	373,77	0,6033	0,7526	476

Окончание таблицы 5
5-кестенің соңы
End of table 5

R3_E0_bce_dice	E0	BCE+Dice	-	0,5945	0,7457	208
Run tag	Object mismatch	Object FN	Pred_pos_ratio	n_CC	Precision	Recall
R0_E100_bce_dice	97	165	0,001851	262	0,9938	0,6014
R1_E100_bce	111	2	0,004052	486	0,8447	0,7844
R2_E100_wbce	4	0	0,008375	495	0,4938	0,8691
R3_E0_bce_dice	93	179	0,001822	252	0,9895	0,5834

6 Процедура обучения и оценки

6.1 Настройки и стратегия обучения

Обучение проводилось в среде Google Colab с GPU-ускорением при параметрах, указанных в таблице 6. Для воспроизводимости стохастические компоненты фиксировались ($seed = 42$).

Перед подачей на вход модели значения отражательной способности нормализовывались единым правилом: значения ограничивались сверху значением 4000, после чего масштабировались делением на 4000. Нормализация применялась одинаково для обучающей, валидационной и тестовой выборок. Финальные веса модели выбирались по результатам валидации 2024 г. в рамках строгого временного разделения.

В рамках исследования были реализованы несколько конфигураций функции потерь для анализа стратегий преодоления дисбаланса классов. В частности, были обучены модели с комбинацией Dice + BCE (R0), с использованием только BCE (R1), а также с Weighted BCE (R2). Дополнительно была протестирована конфигурация без сохранения пустых тайлов (R3). Все модели обучались при идентичных гиперпараметрах и в рамках строгого временного разделения данных. По результатам независимого тестирования 2025 г. конфигурация R2 (Weighted BCE) продемонстрировала наиболее устойчивую стратегию обнаружения с максимальной объектной выявляемостью и была выбрана в качестве базовой модели для дальнейшего анализа.

Таблица 6 – Гиперпараметры обучения модели
6-кесте – Модельді оқытудың гиперпараметрлері
Table 6 – Model training hyperparameters

Параметр	Значение	Параметр	Значение
Архитектура модели	U-Net	Размер батча	8
Энкодер	ResNet-34	Скорость обучения	1×10^{-4}
Веса энкодера	Предобученные на ImageNet	Число эпох	30
Число входных каналов	6 (каналы Sentine l-2)	Оптимизатор	AdamW
Число выходных классов	1 (бинарная классификация: курган / фон)	Функция потерь	Weighted BCE (в зависимости от конфигурации)



6.2 Метрики оценки

Метрики пиксельного уровня (IoU/F1) и правила объектной классификации (TP/mismatch/FN), включая значения порогов t и IoU, формализованы в разделе 5.3.

6.3 Результаты обучения и валидации

В условиях строгого временного разделения данных модель U-Net (R2_E100_wbce) продемонстрировала стабильную сходимость без выраженных признаков переобучения. На обучающем наборе (2021–2023 гг.) были достигнуты значения IoU = 0,700 и F1-мера = 0,814, тогда как на валидационном наборе (2024 г.) соответствующие показатели составили IoU = 0,669 и F1-мера = 0,785.

Бинаризация вероятностной карты выполнялась при фиксированном пороге $t = 0,5$ после применения сигмоидальной функции к выходным логитам. Порог не оптимизировался на тестовом наборе 2025 г. и применялся одинаково для всех временных срезов.

Таблица 7 – Сводка показателей производительности на этапах обучения и валидации
7-кесте – Оқыту және валидация кезеңдеріндегі өнімділік көрсеткіштерінің жиынтығы
Table 7 – Summary of performance metrics during training and validation

Этап	Диапазон данных	IoU	F1-мера
Обучение	2021–2023	≈ 0,70	≈ 0,81
Валидация	2024	≈ 0,67	≈ 0,78

6.4 Инференс и интерпретация результатов

Инференс выполнялся с использованием финальных весов модели и той же стратегии тайлинга (128×128 , шаг 64), что и на этапе обучения. После применения сигмоидной функции формировалась вероятностная карта; бинаризация выполнялась при фиксированном пороге 0,5, одинаковом для всех лет, включая независимый тест 2025 г. В рамках независимого тестирования 2025 г. дополнительные эвристические процедуры пост-обработки (морфологическая фильтрация, удаление малых объектов, фильтрация по площади, сглаживание) не применялись, чтобы итоговые результаты отражали непосредственно выход модели. Для восстановления целостной вероятностной карты из перекрывающихся тайлов использовалось объединение по правилу объединения максимумов (max-merge) (берётся максимальная вероятность среди перекрывающихся предсказаний).

Выход модели интерпретируется как вероятностная разведочная информация, позволяющая ранжировать участки по степени выраженности курганного паттерна и отбирать кандидатов для последующей археологической проверки, а не как окончательная автоматическая классификация.

На рисунке 7 представлены три типичных пространственно-временных отклика модели: (а) выраженный отклик, (б) типичный отклик и (с) характерный сбой в виде чрезмерного расширения ложноположительных зон вокруг слабого истинного сигнала.

Отсутствие FN при $t = 0,5$ подтверждает стратегию модели, ориентированную на минимизацию пропусков потенциальных объектов. В то же время третий случай иллюстрирует цену данной стратегии – локальную переэкспансию ложноположительных зон (FP). Под t стах понимается максимальное число месяцев, в которых данный отклик повторяется во временном ряду; в рассматриваемом примере t стах ≈ 6. Повторяемость сигнала в нескольких месяцах указывает на его устойчивость во времени, однако пространственная экспансия требует последующей фильтрации на этапе интерпретации.

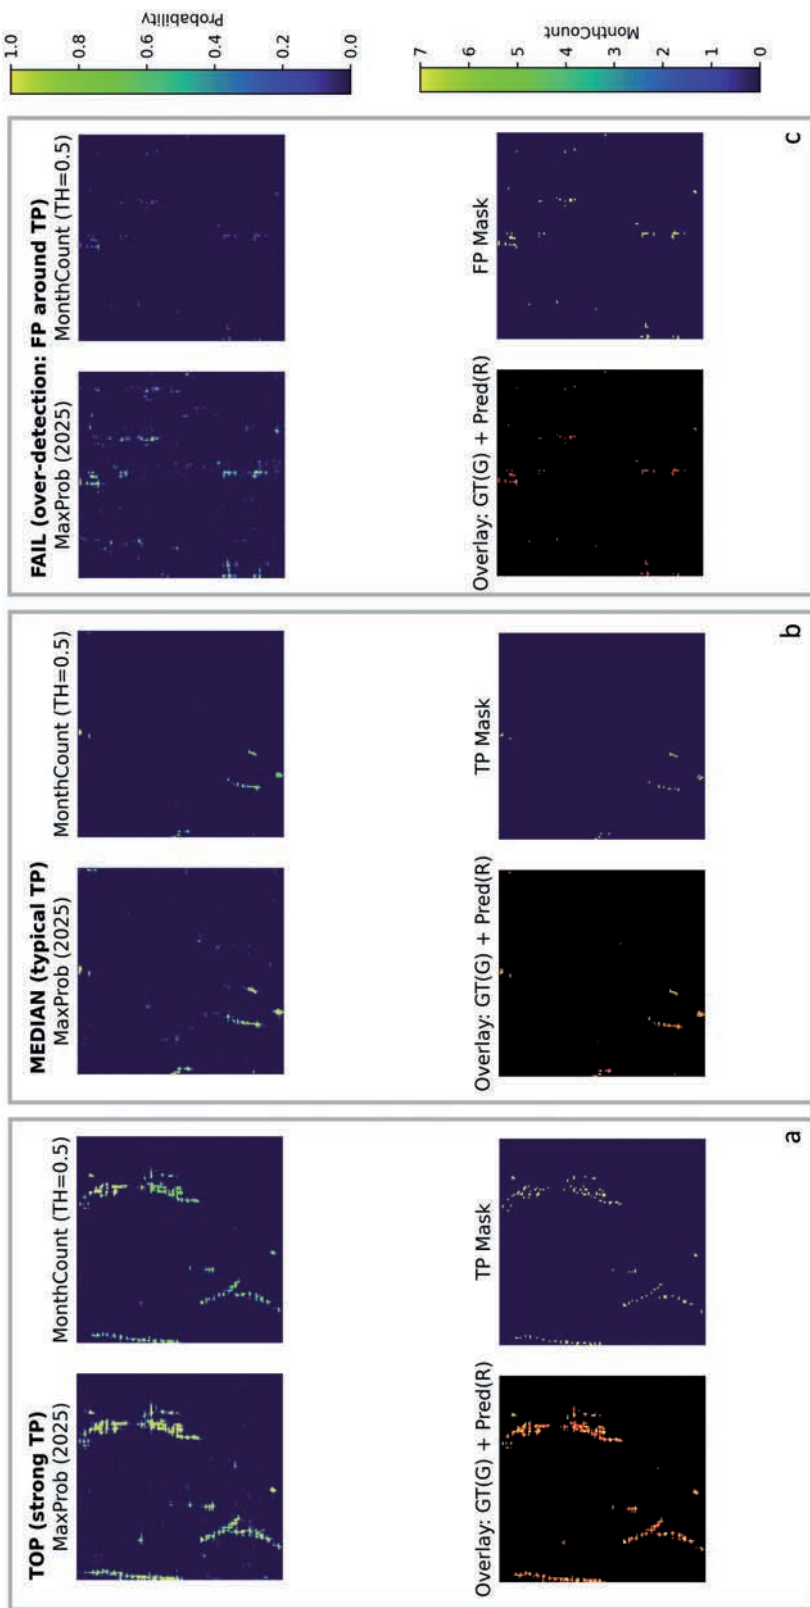


Рис. 7. Характерные пространственно-временные отклики модели: (а) выраженный отклик; (б) типичный отклик; (с) характерный сбой 7-сур. Модельдің өзіне тән кеңістік-уақыттық жауаптары: (а) айқын жауап; (б) типтік жауап; (с) өзіне тән жауап
Fig. 7. Representative spatiotemporal responses of the model: (a) strong response; (b) typical response; (c) failure case



7 Результаты независимого тестирования на основе изображений Sentinel-2 за 2025 г.

В настоящем исследовании было проведено независимое тестирование модели, обученной на данных 2021–2023 гг. и валидированной на данных 2024 г., с использованием изображений Sentinel-2 за период с января по июль 2025 г. Данные 2025 г. не использовались ни на этапе обучения, ни на этапе валидации и служили полностью временно разделённым набором для оценки временной обобщаемости.

7.1 Количественная оценка на пиксельном и объектном уровнях

В дальнейшем анализе в качестве базовой модели используется конфигурация R2 (Weighted BCE, E100), продемонстрировавшая наиболее устойчивую стратегию обнаружения объектов с приоритетом минимизации пропусков (FN).

На пиксельном уровне на независимом тестовом наборе Sentinel-2 за 2025 г. модель достигла IoU = 0,60 и F1-мера = 0,75, при этом Precision составила 0,49 при более высоком Recall = 0,86. Такая комбинация метрик отражает стратегию, ориентированную на повышение чувствительности и снижение риска пропуска курганных объектов, даже ценой увеличения числа ложноположительных откликов. В условиях крайне разреженного положительного класса подобный баланс является ожидаемым и соответствует задаче археологической разведки.

Объектная оценка по ID-маске ($K = 480$) выполнена строго по протоколу, формализованному в разделе 5.3, что обеспечивает сопоставимость с таблицей 5. В результате получено 476 TP, четыре частичных обнаружения (mismatch) и 0 FN, что указывает на высокую степень объектной выявляемости при заданных пространственных допущениях.

Дополнительный анализ чувствительности показал, что варьирование радиуса буфера (1–2 пикселя) влияет на распределение TP и частичных совпадений, однако общая тенденция высокой выявляемости кандидатных позиций сохраняется. Объектные метрики рассматриваются здесь не как абсолютный критерий успешности, а как индикатор способности модели указывать потенциально значимые зоны для последующей интерпретации.

7.2 Минимальная проверка пространственной устойчивости

Пространственная блоковая валидация не являлась центральным элементом исследовательского дизайна данной работы, поскольку модель изначально была ориентирована на оценку временной обобщаемости в условиях изменяющихся сезонных и фоновых характеристик. В отличие от пространственного разделения внутри одного года, строгий временной разрыв 2021–2023 → 2024 → 2025 более реалистично моделирует межгодовой перенос модели в прикладном сценарии использования.

Вместе с тем, для минимальной проверки пространственной устойчивости независимый тест 2025 г. был дополнительно разделён на четыре пространственных блока по координатам тайлов, после чего пиксельные метрики рассчитывались при неизменном пороге бинаризации $t = 0,5$. Полученные результаты демонстрируют сопоставимый уровень качества между блоками (IoU 0,579–0,622; F1 0,733–0,767), а полнота обнаружения (Recall), критически важная для задач археологической разведки, сохраняется в диапазоне 0,838–0,857. Это свидетельствует об отсутствии значимой деградации качества при переходе между различными участками базовой АОИ и позволяет рассматривать риск локальной переадаптации к частному фоновому контексту как ограниченный.

7.3 Пространственные паттерны обнаружения на основе карты вероятностей

Карты вероятностей формируют пространственно связанные зоны повышенной вероятности, а не дискретные одиночные пиксели, что указывает на усвоение моделью пространственных паттернов.

Типичные примеры распределения TP/FP (рис. 8) показывают, что основные ошибки связаны с локальными ложноположительными зонами, тогда как пропуски (FN) при $t = 0,5$ практически

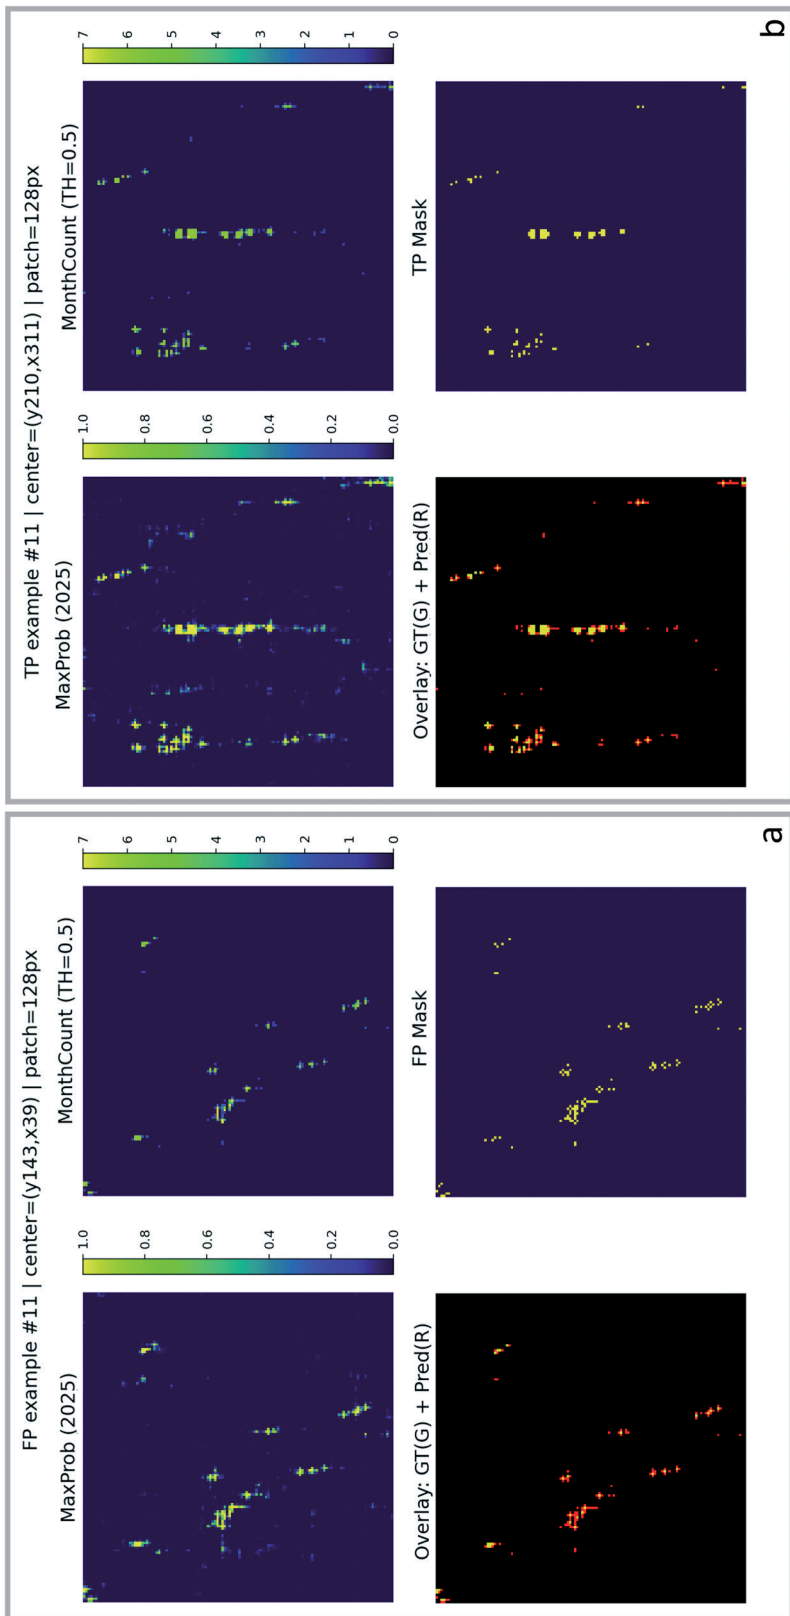


Рис. 8. Типология ошибок модели на тестовом наборе 2025 г.: (а) FP; (б) FN
8-сур. 2025 ж. сынақ жиынтықтағы модель қателерінің типологиясы: (а) FP; (б) FN
Fig. 8. Typology of model errors on the 2025 test set: (a) FP; (b) FN



отсутствуют. При этом даже в случаях частичного обнаружения фиксируется устойчивая пространственная реакция вокруг эталонной точки.

Карта краткосрочной повторяемости (Temporal Consistency Map; рис. 9) дополнительно выделяет устойчивые во времени отклики и служит инструментом приоритизации кандидатных зон, хотя данный анализ объективно ограничен данными одного года.

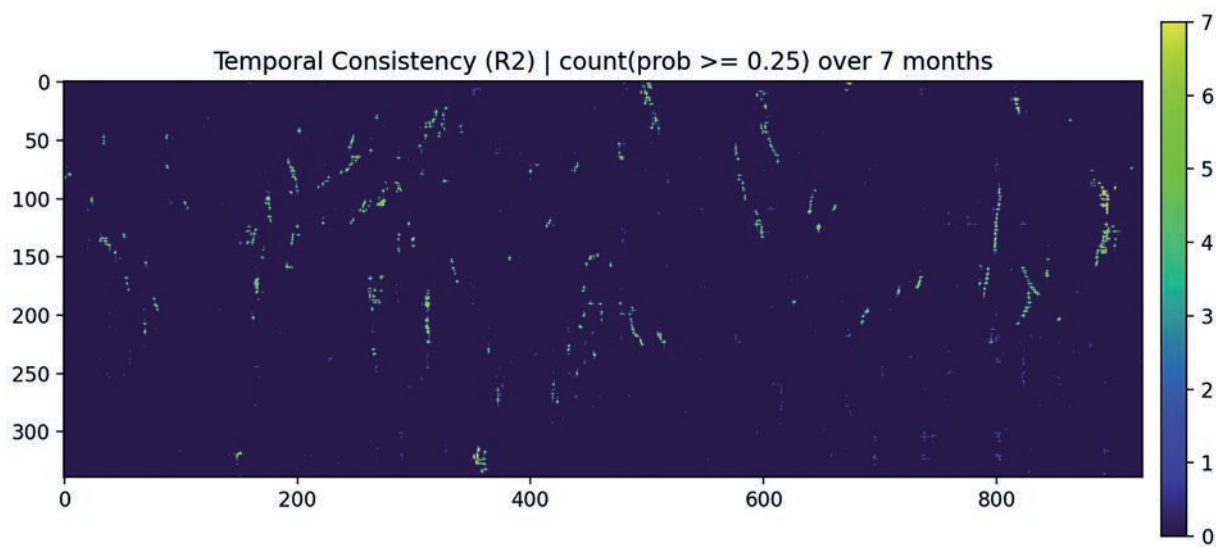


Рис. 9. Карта краткосрочной повторяемости за 2025 г. (накопленная повторяемость вероятностных откликов) 9-сур. 2025 ж. қысқамерзімді қайталау картасы (ықтималдық жауаптарының жинақталған қайталануы)
Fig. 9. Short-term recurrence map for 2025 showing cumulative model probability responses

7.4 Археологическая интерпретация и возможности применения

С археологической точки зрения ключевой задачей обнаружения курганов является не полное совпадение отдельных пикселей, а способность надежно указывать участки, представляющие интерес для полевых исследований и дополнительной интерпретации. Результаты независимого тестирования показали, что при сохранении приемлемых пиксельных метрик (IoU и F1-мера) объектные показатели могут варьироваться в зависимости от выбранных пространственных допущений, что подчеркивает необходимость многомерной интерпретации результатов.

С практической точки зрения пространственная фильтрация, обеспечиваемая моделью, приводит к существенному сокращению площади территории, требующей предварительного этапа полевых разведочных обследований. При пороге бинаризации $t = 0,5$ суммарная площадь зон с вероятностью выше порога составляет $0,263 \text{ км}^2$ из общей площади АОИ $31,39 \text{ км}^2$, что соответствует $0,84\%$ территории. Иными словами, при сохранении высокой полноты обнаружения ($FN = 0$ в объектной оценке) модель позволяет сократить пространственный объём первичного визуального анализа и предварительной разведки более чем на 99% .

При дополнительном учёте краткосрочной повторяемости откликов (monthcount – число месяцев превышения порога; monthcount ≥ 3) площадь приоритетных участков уменьшается до $0,144 \text{ км}^2$ ($0,46\%$ от АОИ) без существенного снижения чувствительности модели.



8 Заключение

В исследовании предложена методология выявления курганов по временным рядам Sentinel-2 с использованием U-Net, акцентирующая внимание на временной обобщаемости и вероятностной интерпретации результатов. Обучение и оценка модели осуществлялись с применением стратегии строгого временного разделения данных. Результаты обучения и валидации показали отсутствие выраженного переобучения и сохранение стабильной производительности при переходе между временными срезами. Независимое тестирование на данных Sentinel-2 за 2025 г. продемонстрировало способность модели выявлять курганы в новых временных условиях и свидетельствует о том, что модель воспринимает курганы не как объекты с чётко очерченными границами, а как вероятностные пространственные структуры, проявляющиеся в зонах с повторяющимися откликами.

Полученные результаты указывают на целесообразность переосмысления задачи обнаружения курганов как задачи пространственного поиска и ранжирования кандидатных участков, а не точного восстановления контуров. Выходные данные модели следует рассматривать как разведочную информацию, предназначенную для поддержки экспертной интерпретации и планирования полевых исследований, а не как автоматическое окончательное решение.

Таким образом, предложенная методика не предназначена для окончательной автоматической идентификации археологических объектов. Пространственное разрешение Sentinel-2 (10 м) объективно ограничивает возможность точной морфометрической реконструкции малых курганов. В этой связи модель должна рассматриваться прежде всего как инструмент предварительного выявления и ранжирования перспективных участков, требующих последующей экспертной оценки и полевой верификации.

Ограничения исследования связаны с использованием исключительно оптических данных Sentinel-2; в последующих работах планируется расширение входных данных за счёт Sentinel-1 и/или DEM, а также тестирование переноса на более широкие территории. В целом настоящее исследование демонстрирует потенциал использования временных рядов спутниковых изображений и методов глубинного обучения для выявления курганов с одновременным учётом временной обобщаемости и пространственной интерпретируемости и может служить методологической основой для дальнейших исследований в области археологического дистанционного зондирования.

REFERENCES

- 1 Berganzo-Begas I., Orengo, H. A., Lumbreras, F., Carrero-Pazos, M., Fonte, J., Vilas- Estévez, B. 2021, Hybrid MSRM-Based Deep Learning and Multitemporal Sentinel 2-Based Machine Learning Algorithm Detects Near 10k Archaeological Tumuli in North-Western Iberia. *Remote Sensing* 13(20), 4181, 1–18.
- 2 Caspari, G., Crespo, P. 2019. Convolutional neural networks for archaeological site detection – Finding “princely” tombs. *Journal of Archaeological Science* 110, 104998, 1–26.
- 3 Guyot, A., Hubert-Moy, L and Lorho, T. 2018. Detecting Neolithic Burial Mounds from LiDAR-Derived Elevation Data Using a Multi-Scale Approach and Machine Learning Techniques. *Remote Sensing* 10 (2), 225, 1–19.
- 4 Jakubczak, M., Tyszkiewicz, M. J., Leloch, M. 2024, The Application of Artificial Intelligence and Machine Learning in Archaeology: Methodological Challenges and a Case Study from Poland. *Res. Sq.*, 1–24.
- 5 Kokalj, Ž., Džeroski, S., Šprajc, I., Štajdohar, J., Draksler, A., & Somrak, M. 2023. Machine learning-ready remote sensing data for Maya archaeology. *Scientific Data* 10 (1), 558, 1–13.
- 6 Koziol, K., Borowiec, N., Marmol, U., Rzeszutek, M., Santos, C., Czerniec, J. 2025. Machine Learning-Based Detection of Archeological Sites Using Satellite and Meteorological Data: A Case Study of Funnel Beaker Culture Tombs in Poland. *Remote Sensing* 17(13), 2225, 1–24.
- 7 Kramer, I. 2023, AI Mound Detection in Ukraine: a Collaboration Between AARG and ArchAI, Technical Report, 1–28.



- 8 Meyer-Heß, M.F., Pfeffer I., & Juergens, C. 2022. Application of convolutional neural networks on digital terrain models for analyzing spatial relations in archaeology. *Remote Sensing* 14(11), 2535, 1–16.
- 9 Orengo, H. A., Conesa, F. C., Garcia-Molsosa, A., Lobo, A., Green, A. S., Madella, M., Petrie, C. A. 2020. Automated detection of archaeological mounds using machine-learning classification of multisensory and multitemporal satellite data. *Proc. Natl. Acad. Sci. U S A.* 117 (31), 18240–18250.
- 10 Trier, Ø. D., Reksten, J. H., Løseth, K. 2021. Automated mapping of cultural heritage in Norway from airborne lidar data using faster R-CNN. *International Journal of Applied Earth Observation and Geoinformation* 95, 102241, 1–19.
- 11 Verschoof-van der Vaart, W.B., Lambers, K. 2019. Learning to look at LiDAR: the use of R-CNN in the automated detection of archaeological objects in LiDAR data from the Netherlands. *Journal of Computer Applications in Archaeology* 2 (1), 31–40.

Мүдделер қақтығысы туралы ақпаратты ашу. Авторлар мүдделер қақтығысының жоқтығын мәлімдейді.
/ Раскрытие информации о конфликте интересов. Авторы заявляют об отсутствии конфликта интересов.
/ Disclosure of conflict of interest information. The authors claim no conflict of interest.
Мақала туралы ақпарат / Информация о статье / Information about the article.
Редакцияға түсті / Поступила в редакцию / Entered the editorial office: 28.01.2026.
Рецензенттер мақұлдаған / Одобрено рецензентами / Approved by reviewers: 25.02.2026.
Жариялауға қабылданды / Принята к публикации / Accepted for publication: 03.03.2026.

