

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МУЛЬТИСЕНСОРНЫЕ ДАННЫЕ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ДЛЯ МОНИТОРИНГА ГОРОДСКИХ ЗЕМЕЛЬ: ВОЗМОЖНОСТИ, ОГРАНИЧЕНИЯ И ПЕРСПЕКТИВЫ (на примере г. Ханоя, Вьетнам)

Нгуен Тхи Чам, аспирантка

Московский государственный университет геодезии и картографии (МИИГАиК), Москва

Секция: «Технологии и методы использования спутниковых данных в системах мониторинга»

УДК 528.8:004.8

Аннотация

Быстрая трансформация городской территории Ханоя повышает требования к оперативному, пространственно детализированному и воспроизводимому мониторингу земного покрова и землепользования. Современные спутниковые системы Landsat, Sentinel-1 и Sentinel-2 обеспечивают многолетние и регулярно обновляемые ряды наблюдений, однако практическим ограничением всё чаще становится не получение изображений, а автоматизированная обработка больших объёмов разновременных и разнородных данных. В работе систематизированы возможности методов искусственного интеллекта (ИИ) — Random Forest, Support Vector Machine, свёрточных нейронных сетей, U-Net, сиамских архитектур, трансформеров и геопространственных фундаментальных моделей — для мониторинга городской территории. На примере Ханоя обобщены опубликованные результаты исследований 2000–2023 гг.: выявлено расширение городской территории на 30 697,8 га; интеграция Landsat и Sentinel-1 обеспечила точность классификации 93% при коэффициенте Кэрра 0,80, а чистая потеря растительного покрова составила 4 319 га [1]. Дополнительное исследование на основе Landsat показало, что более 56% территории города характеризуется сильной отрицательной корреляцией NDVI и NDBI ($r < -0,5$) [2]. Показаны преимущества облачной обработки в Google Earth Engine, мультисенсорного объединения оптических и радиолокационных данных и локального дообучения моделей. Отдельно рассмотрены ограничения, связанные с качеством обучающих выборок, переносом моделей между регионами, облачностью, интерпретируемостью и вычислительными затратами. Обосновывается перспективность применения геопространственных фундаментальных моделей, включая Prithvi и SatMAE, в сочетании с локальной валидацией и экспертным контролем.

Ключевые слова: дистанционное зондирование Земли; искусственный интеллект; машинное обучение; глубокое обучение; мониторинг городских земель; выявление изменений; Sentinel-1; Sentinel-2; Landsat; Google Earth Engine; Ханой; Вьетнам.

1. Постановка проблемы

Урбанизация Вьетнама сопровождается преобразованием сельскохозяйственных и природных земель, ростом застроенных площадей и изменением структуры зелёного покрова. По данным Всемирного банка, доля населения Вьетнама, проживающего в городских районах, выросла примерно с 24% в 2000 г. до более 34% в 2015 г.; в базе World Development Indicators фиксируется дальнейший рост городского населения [3]. Эти процессы особенно заметны в Ханое, где расширение городской

территории происходит одновременно с изменением периферийных сельскохозяйственных и зелёных зон.

Для мониторинга таких процессов традиционные наземные обследования остаются необходимыми, но их периодичность, стоимость и пространственная неоднородность ограничивают возможность регулярного получения единой картины. Спутниковые данные позволяют перейти к систематическому наблюдению. Landsat обеспечивает длительный исторический ряд, а Sentinel-1 и Sentinel-2 дополняют его радиолокационными и оптическими наблюдениями. Sentinel-1 способен получать данные независимо от освещённости и при наличии облачности, что особенно важно для тропических территорий [4].

Одновременно объём данных растёт настолько быстро, что задача смещается от простого получения снимков к их автоматизированному анализу. В работе PhilEO Bench отмечается, что только созвездие Sentinel-2 генерирует порядка 1,6 ТБ данных в сутки; авторы также подчёркивают дефицит качественных размеченных данных как один из основных барьеров для применения ИИ в Earth Observation [5].

Следовательно, для городского мониторинга целесообразно формировать не отдельный алгоритм классификации, а воспроизводимый технологический контур: спутниковые данные → предварительная обработка → мультисенсорное объединение → ИИ-классификация/сегментация → выявление изменений → валидация → тематические показатели для кадастрового и градостроительного анализа.

2. Материалы и методический подход

Настоящая работа имеет обзорно-аналитический характер. Численные показатели, приведённые для Ханоя, основаны на опубликованных исследованиях и открытых геопространственных продуктах; они не выдаются за результаты нового независимого эксперимента автора. Такой подход позволяет сопоставить локальные результаты Ханоя с современными методами ИИ и определить перспективную схему их применения.

В качестве базовых источников данных целесообразно использовать: (1) Landsat для построения длинных временных рядов; (2) Sentinel-2 для многоспектральной съёмки с пространственным разрешением 10 м по наиболее востребованным каналам; (3) Sentinel-1 для радиолокационного наблюдения, устойчивого к облачности; (4) Dynamic World как глобальный продукт земного покрова с разрешением 10 м и девятью классами, формируемый на основе Sentinel-2; (5) World Settlement Footprint (WSF) для независимой оценки пространственного распространения застройки [4,6,7].

Google Earth Engine (GEE) рассматривается как среда для формирования композитов, маскирования облачности, расчёта спектральных индексов, выборки обучающих данных и запуска масштабируемых процедур машинного обучения. Платформа специально создана для планетарного анализа геопространственных данных и сочетает большой каталог данных с облачными вычислительными ресурсами [8].

Для городского мониторинга рекомендуется использовать не только спектральные признаки, но и производные показатели. К ним относятся NDVI для растительного покрова, NDBI для выявления застроенных территорий, водные индексы для водных объектов, а также статистики и текстурные

признаки Sentinel-1. При наличии цифровой модели рельефа могут дополнительно использоваться высота, уклон и экспозиция.

Методический контур ИИ включает два уровня. Первый — классическое машинное обучение (RF, SVM), которое удобно для сравнительно небольших обучающих выборок и интерпретируемого базового моделирования. Второй — глубокое обучение (CNN, U-Net, Siamese networks, Vision Transformers), которое целесообразно при наличии достаточного объёма размеченных данных и необходимости точного выделения пространственных границ объектов.

Технологическая схема AI-мониторинга городских земель Ханоя



Рис. 1. Технологическая схема AI-мониторинга городских земель Ханоя.

Составлено автором на основе описанного в работе технологического подхода.

3. Методы искусственного интеллекта для городского мониторинга

3.1. Классическое машинное обучение

Random Forest и Support Vector Machine остаются востребованными для классификации земного покрова благодаря устойчивости к многомерным признакам и возможности работать с ограниченными обучающими выборками. Для Ханоя особенно перспективна комбинация оптических признаков Sentinel-2/Landsat с радиолокационными признаками Sentinel-1. Такой подход уменьшает зависимость результата от облачности и позволяет различать некоторые спектрально сходные городские поверхности.

При этом RF и SVM не следует рассматривать как универсальное решение. В плотной городской застройке небольшие объекты, тени, различные типы кровель и сезонные изменения создают внутриклассовую неоднородность. Поэтому при переходе к задачам попиксельной сегментации и точного выявления новых объектов преимущества постепенно смещаются в сторону глубоких моделей.

3.2. Глубокое обучение и семантическая сегментация

U-Net сформировал один из наиболее распространённых принципов encoder–decoder для попиксельной сегментации [9]. В задачах городского мониторинга он может применяться для выделения зданий, дорог, водных объектов, растительности и других классов. Сиамские сети используют два связанных потока для анализа двух дат наблюдений и поэтому естественно подходят для change detection.

Современное направление связано с объединением CNN и трансформеров. Например, опубликованная в 2025 г. архитектура DSHA объединяет ResNet34 и модифицированный Pyramid Vision Transformer (PVT-v2). На наборе LEVIR-MCI авторы получили mIoU 92,28% и F1-score 92,50%; эти значения относятся к экспериментам на указанном бенчмарке и не должны напрямую переноситься на Ханой без локальной проверки [10].

Другой актуальный подход — ANITA, архитектура для многовременного картографирования городской территории, использующая геопространственно-временное выравнивание и self-training для уменьшения влияния временного domain shift [11]. Для тропических городов, где сезонность и атмосферные условия заметно меняют вид поверхности, временная адаптация имеет принципиальное значение.

3.3. Геопространственные фундаментальные модели

Следующим этапом развития являются foundation models для Earth Observation. Prithvi был разработан NASA и IBM как геопространственная фундаментальная модель, предварительно обученная на многолетних мультиспектральных данных Harmonized Landsat Sentinel-2 (HLS). Такой подход позволяет использовать предварительно выученные представления и затем дообучать модель под конкретную прикладную задачу на меньшем объеме размеченных данных [12].

SatMAE применяет Masked Autoencoder к временным и мультиспектральным спутниковым данным. В исходной работе авторы сообщают улучшение результатов на ряде задач дистанционного зондирования до 7% для supervised learning и до 14% для transfer learning по сравнению с соответствующими базовыми подходами [13]. Для Ханоя это особенно интересно, поскольку полноценная локальная разметка всей территории города является дорогостоящей.

При этом foundation model не отменяет локальную валидацию. Бенчмарк PhilEO Bench включает 400 ГБ Sentinel-2 данных и задачи оценки плотности зданий, сегментации дорог и классификации земного покрова; его разработчики подчёркивают проблему дефицита разметки и необходимость сопоставимой оценки геопространственных фундаментальных моделей [5].




Рис. 2. Динамика основных классов LULC в Ханое и прилегающей зоне, 1989–2019 гг.
 Составлено по данным опубликованного исследования [1]; значения приведены в процентах территории.

4. Ханой как тестовая территория

Ханой представляет собой показательный объект для анализа городской трансформации в условиях тропического муссонного климата. Важной особенностью является сочетание плотной городской застройки, пригородных сельскохозяйственных территорий, рек, озёр, каналов и крупных зелёных зон. Это создаёт одновременно высокую тематическую ценность мониторинга и высокую сложность автоматической классификации.

По исследованию Ноан и соавторов, выполненному с использованием GEE и интеграции Landsat и Sentinel-1, в период 2000–2023 гг. городская территория Ханоя расширилась на 30 697,8 га. В том же исследовании общая точность классификации составила 93%, а коэффициент Карра — 0,80. Авторы также оценили чистую потерю растительного покрова в 4 319 га [1]. Эти показатели являются непосредственно релевантными для обоснования необходимости автоматизированного мультисенсорного мониторинга.

Независимое исследование Quynh и соавторов, опубликованное в 2025 г., показало пространственно неоднородную динамику растительности. В отдельных периферийных районах зафиксировано сокращение растительного покрова: Nam Tu Liem –690 га, Hoai Duc –650 га, Ung Hoa –629 га и Ha Dong –588 га. В то же время Ba Vi (+807 га), Gia Lam (+664 га) и Son Tay (+230 га) показали увеличение. Более 56% территории города характеризовалось сильной отрицательной корреляцией между NDVI и NDBI ($r < -0,5$), что указывает на тесную связь между урбанизацией и сокращением растительности [2].

Дополнительное исследование городской экспансии пяти мегаполисов Юго-Восточной Азии, опубликованное в 2026 г., оценило рост урбанизированной территории Ханоя с 362,58 до 627,93 км²

между периодами 2000–2004 и 2020–2024 гг., то есть на 265,35 км² (73,2%). При этом Ханой был отнесён к типу городов с быстрым расширением и относительно фрагментированной пространственной структурой [14]. Различия между этим показателем и 30 697,8 га из [1] связаны с различиями в определении временных срезов, методике и понятии «городской территории», поэтому эти значения не следует механически объединять.

Для оперативного мониторинга Ханоя целесообразно строить модель не только на одном снимке, но на временной серии. В качестве независимых контрольных продуктов могут использоваться Dynamic World и WSF. Dynamic World обеспечивает глобальную LULC-классификацию с разрешением 10 м и девятью классами, а WSF2019 предоставляет бинарную маску поселений с разрешением 10 м [6,7].




Рис. 3. Диапазоны значений NDVI, NDBI и NDWI в Ханое в 1998, 2010 и 2022 гг.
Составлено по данным опубликованного исследования [2].

5. Рекомендуемая технологическая схема мониторинга

- 1) Формирование АОИ Ханоя и единой пространственной сетки.
- 2) Загрузка временных серий Landsat, Sentinel-1 и Sentinel-2 в GEE.
- 3) Маскирование облаков и теней, радиометрическая и геометрическая подготовка.
- 4) Формирование сезонных или годовых композитов и расчёт NDVI, NDBI и дополнительных признаков.
- 5) Объединение оптических и SAR-признаков.
- 6) Подготовка обучающей и независимой валидационной выборок.
- 7) Построение базовых моделей RF/SVM и сравнение их с CNN/U-Net или transformer-based моделями.

- 8) Выявление изменений по парам дат и многовременным последовательностям.
- 9) Валидация по OA, Precision, Recall, F1-score, IoU и Карра; обязательная оценка матрицы ошибок по каждому классу.
- 10) Экспертная проверка наиболее важных изменений и подготовка карт для градостроительного и кадастрового использования.

6. Количественные критерии оценки

Для корректного сравнения алгоритмов рекомендуется использовать несколько взаимодополняющих показателей. Overall Accuracy (OA) характеризует долю правильно классифицированных пикселей, но может быть завышена при дисбалансе классов. Поэтому необходимо дополнительно использовать F1-score, Intersection over Union (IoU), Precision и Recall по отдельным классам. Коэффициент Карра целесообразно сохранять как традиционный показатель согласия классификации, но интерпретировать его совместно с матрицей ошибок.

Для change detection особенно важны IoU и F1-score класса «изменение», поскольку доля изменившихся пикселей обычно значительно меньше доли стабильной территории. Для практического городского мониторинга следует также оценивать минимальный размер обнаруживаемого объекта и пространственную точность его границ, поскольку высокая общая точность не гарантирует корректного выделения небольших строительных объектов.


7. Ограничения применения ИИ

Первое ограничение — дефицит локальных размеченных данных. Для Ханоя необходимы эталонные выборки, учитывающие различные типы кровель, плотность застройки, сельскохозяйственные культуры, водные поверхности и сезонные состояния растительности. Второе — domain shift: модель, обученная на одном городе или климатическом регионе, может заметно терять точность при переносе.

Третье — облачность и атмосферные эффекты. Для тропического Вьетнама использование только оптических данных создаёт пропуски во временных рядах; поэтому Sentinel-1 является важным дополнением. Четвёртое — вычислительные ресурсы и стоимость обучения больших моделей. Пятое — интерпретируемость. Для кадастровых и управленческих решений недостаточно получить красивую карту: необходимо иметь возможность проверить происхождение результата и его неопределённость.

Наконец, глобальные продукты не следует автоматически считать эталоном. Dynamic World и WSF полезны как независимые источники сравнения, но их пространственная и тематическая точность может зависеть от класса, региона, сезона и характера застройки. Поэтому для Ханоя предпочтительна схема «глобальная модель/продукт → локальное дообучение → независимая полевая или высокодетальная валидация».

Концептуальная схема применения геопространственной foundation model



Идея основана на принципах Prithvi и SatMAE; схема является авторской иллюстрацией.

Рис. 4. Концептуальная схема применения геопространственной foundation model для Ханоя.

Авторская схема на основе принципов Prithvi и SatMAE [12, 13].

8. Перспективы развития

Наиболее перспективным направлением представляется переход от разрозненных алгоритмов к единой системе AI-assisted Earth Observation. Такая система должна объединять временные ряды Sentinel-1/2 и Landsat, облачную обработку GEE, foundation models, локальные обучающие выборки и экспертную верификацию.

Для Ханоя можно сформировать специализированный набор данных, включающий ежегодные или сезонные карты застройки, растительности, воды и сельскохозяйственных территорий, а также отдельный слой изменений. На следующем этапе foundation model может быть дообучена на этих данных. Это позволит проверить, насколько предварительно обученные геопространственные представления действительно переносятся на тропический мегаполис и уменьшают потребность в ручной разметке.

Практический результат такой системы — не только карта земного покрова, но и система индикаторов: прирост застроенной площади, потеря/восстановление зелёных зон, изменение водных объектов, появление новых строительных площадок, динамика пригородной территории и зоны потенциального экологического риска.




Рис. 5. Примеры опубликованных показателей точности для задач городского мониторинга.

Источники: [1] — Ханой; [15] — картографирование LULC Вьетнама; [10] — DSHA на LEVIR-MCI. Показатели относятся к разным экспериментам и не являются прямым сравнением моделей.

Примечание к рисункам. Рисунки 1 и 4 являются авторскими схемами. Рисунки 2–3 визуализируют опубликованные численные данные, а не новые экспериментальные результаты автора.

9. Выводы

1. Современный этап дистанционного зондирования характеризуется переходом от проблемы получения спутниковых данных к проблеме их масштабируемой и интеллектуальной обработки.
2. Для Ханоя опубликованные исследования уже показывают значительную городскую трансформацию: расширение городской территории на 30 697,8 га за 2000–2023 гг., точность 93% и Карра 0,80 для интегрированной классификации Landsat/Sentinel-1, а также чистую потерю растительного покрова 4 319 га [1].
3. Сильная отрицательная связь NDVI и NDBI более чем на 56% территории Ханоя подтверждает необходимость совместного мониторинга урбанизации и зелёной инфраструктуры [2].
4. RF и SVM остаются эффективными базовыми моделями, однако U-Net, сиамские сети и гибридные CNN–Transformer архитектуры лучше соответствуют задачам детальной сегментации и выявления пространственных изменений.
5. Геопространственные foundation models, включая Prithvi и SatMAE, открывают возможность снизить зависимость от больших локальных обучающих выборок, но требуют обязательного локального fine-tuning и независимой валидации.
6. Для Вьетнама наиболее перспективна мультисенсорная схема Landsat + Sentinel-1 + Sentinel-2 в облачной среде GEE с последующим применением ИИ и экспертным контролем.

7. Предлагаемый подход может стать основой методики оперативного мониторинга городских земель Ханоя и, после проверки переносимости, других быстро урбанизирующихся городов Вьетнама.

Список литературы

1. 1. Hoan N.T., Quynh H.T., Hoang V.T., Thu H.L., Dung N.V., Tuan N.A. Monitoring urban dynamics and their impact on Hanoi's green ecosystem using integrated Landsat and Sentinel-1 observations. *Applied Ecology and Environmental Research*, 2025. DOI/URL: https://aloki.hu/pdf/2303_58835903.pdf.
2. 2. Quynh H.T., Hoan N.T., Tuan N.A., Thu H.L., Dung N.V., Hoang V.T. Assessment of Vegetation Cover Dynamics and Its Relationship with Urbanization in Hanoi from 2000 to 2023 Using Multi-temporal Remote Sensing Data. *VNU Journal of Science: Earth and Environmental Sciences*. 2025. Vol. 41, No. 4. DOI: 10.25073/2588-1094/vnuees.5319.
3. 3. World Bank. World Development Indicators: Viet Nam. Indicators: Urban population (% of total population); Urban population growth (annual %). World Bank DataBank.
4. 4. European Space Agency (ESA). Sentinel-1: Radar vision for Copernicus. Mission description and operational characteristics. 2026.
5. 5. Fibaek C., Camilleri L., Luyts A., Dionelis N., Le Saux B. PhilEO Bench: Evaluating Geo-Spatial Foundation Models. *IGARSS 2024. IEEE*, 2024, pp. 2739–2744. DOI: 10.1109/IGARSS53475.2024.10642780.
6. 6. Brown C.F., Brumby S.P., Guzder-Williams B., et al. Dynamic World, Near real-time global 10 m land use land cover mapping. *Scientific Data*. 2022. Vol. 9, Article 251. DOI: 10.1038/s41597-022-01307-4.
7. 7. DLR/EOC. World Settlement Footprint 2019 (WSF2019): 10 m global settlement extent derived from multitemporal Sentinel-1 and Sentinel-2 imagery. DOI: 10.15489/twg5xsnquw84.
8. 8. Gorelick N., Hancher M., Dixon M., Ilyushchenko S., Thau D., Moore R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*. 2017. Vol. 202. P. 18–27. DOI: 10.1016/j.rse.2017.06.031.
9. 9. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *MICCAI 2015. LNCS 9351*. P. 234–241. DOI: 10.1007/978-3-319-24574-4_28.
10. 10. Ahmad I., Shang F., Pathan M.S., Wajahat A., et al. Dual-stream hybrid architecture with adaptive multi-scale boundary-aware mechanisms for robust urban change detection in smart cities. *Scientific Reports*. 2025. Vol. 15, Article 30729. DOI: 10.1038/s41598-025-16148-5.
11. 11. Shi S., Liu Y., Li D., Zhong Y. Multi-temporal high-resolution urban land-use mapping and change analysis based on a deep geospatial-temporal adaptation network. *Remote Sensing of Environment*. 2025. Vol. 328, Article 114912. DOI: 10.1016/j.rse.2025.114912.
12. 12. NASA/IBM. Prithvi: A Foundation Model for Geospatial AI. NASA/IBM, 2023–2024. Model pre-trained on Harmonized Landsat Sentinel-2 (HLS) data.

13. 13. Cong Y., Khanna S., Meng C., Liu P., Rozi E., He Y., Burke M., Lobell D., Ermon S. SatMAE: Pre-training Transformers for Temporal and Multi-Spectral Satellite Imagery. *Advances in Neural Information Processing Systems* 35 (NeurIPS 2022). DOI: 10.52202/068431-0015.

14. 14. Temporally consistent mapping of urban expansion in five Southeast Asian megacities. 2026. ScienceDirect. Исследование сопоставляет динамику Бангкока, Ханоя, Манилы, Джакарты и Хошимина за 2000–2024 гг.

Примечание редактора

В текущей редакции намеренно исключены или переформулированы неподтверждённые утверждения из исходного текста — в частности, фраза о том, что локальная модель Random Forest для Ханоя якобы стабильно даёт ОА >94% и Карра >0,91, если она не сопровождается первичным источником с воспроизводимой методикой. Также уточнено, что показатели DSHA, SatMAE и других моделей относятся к их исходным бенчмаркам, а не к Ханюю. Перед подачей тезисов рекомендуется привести список литературы и оформление ссылок в точное соответствие с шаблоном оргкомитета XXIV Международной конференции.

15. Li X., Zhang X., et al. JAXA's new high-resolution land use land cover map for Vietnam using a time-feature convolutional neural network. *Scientific Reports*. 2024. Vol. 14. DOI: 10.1038/s41598-024-54308-1.