

DOI 10.24412/1829-0450-fm-2026-1-76-84  
УДК 519.688

Поступила: 20.03.2026г.  
Сдана на рецензию: 23.03.2026г.  
Подписана к печати: 27.03.2026г.

## АЛГОРИТМ ГЕНЕРАЦИИ СИНТЕТИЧЕСКИХ ДАННЫХ ДЛЯ ЗАДАЧ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ НА ОСНОВЕ UNREAL ENGINE 5

*К.С. Сурменелян, А. Ж. Арамян, О.А. Ованнисян, М.М.Смбатян,  
В.Т. Погосян, А.А. Маладжян*

*Российско-Армянский университет*

*karolina.surmenelyan@student.rau.am, aramyan.arpine@student.rau.am,  
olga.hovhannisyanyan@ispras.ru, meri.smbatyan@student.rau.am,  
vik.poghosyan01@gmail.com, malajyanartur@gmail.com*

### АННОТАЦИЯ

В данной статье представлен алгоритм генерации синтетических данных для задач дистанционного зондирования, реализованный в среде Unreal Engine 5. Подход основан на процедурном моделировании городской среды, стохастическом размещении объектов с геометрическими и семантическими ограничениями и моделировании параметров виртуальной камеры. Аннотации формируются автоматически из трехмерной сцены и включают ограничивающие рамки и семантические маски. Предложенный алгоритм обеспечивает согласованность между изображениями и разметкой и позволяет масштабируемо генерировать обучающие данные для задач компьютерного зрения в дистанционном зондировании.

**Ключевые слова:** синтетические данные, “Unreal Engine 5”, дистанционное зондирование, автоматическая разметка, компьютерное зрение.

### Введение

Одной из ключевых проблем компьютерного зрения в дистанционном зондировании является ограниченная доступность и несовершенное качество размеченных данных (Рис.1). В отличие от обычных фотографий, данные аэросъемки и спутникового мониторинга характеризуются высокой плотностью объектов, вариативностью углов обзора и сильной зависимостью от условий освещения и атмосферных явлений. Традиционная ручная разметка таких изображений трудозатратна, подвержена ошибкам интерпретации и часто не позволяет достичь пиксельной точности, необходимой для современных глубоких нейронных сетей, что, в конечном итоге, снижает их обобщающую способность.




Рис. 1. Сравнение масок Change Detection: SYSU-CD (верх) и наши синтетические данные (низ).

Для уменьшения зависимости от ручной разметки применяются методы самообучения и полуконтролируемого обучения [1, 2], однако они по-прежнему функционально зависят от специфики данных целевой области и крайне чувствительны к шуму в метках. Генеративные модели, включая современные диффузионные архитектуры [3, 4], позволяют синтезировать визуально реалистичные изображения, но обладают существенным недостатком: они обеспечивают ограниченный контроль над геометрией сцены и физическими параметрами съемки (высота, фокусное расстояние, угол наклона камеры). Более того, такие модели не гарантируют получение точной и семантически согласованной разметки.

В отличие от них, использование специализированных 3D-симуляций позволяет полностью автоматизировать процесс аннотирования и реализовать концепцию управляемой генерации. Это дает возможность явно задавать состав сцены и параметры виртуального сенсора, получая идеально согласованные пары «изображение-маска» [5, 6].

Целью данной работы является описание алгоритма генерации синтетических данных для задач дистанционного зондирования на базе “Unreal Engine 5” [7], позволяющего создавать реалистичные сцены и автоматически извлекать точные аннотации из виртуальной среды. В отличие от существующих подходов, предлагаемый алгоритм реализует процедурный метод формирования локаций и стохастическое размещение объектов с учетом их физического взаимодействия. Это обеспечивает строгий контроль над геомет-

рией сцены и метаданными аннотаций, формируя качественные наборы данных для предобучения моделей в условиях дефицита реальных размеченных выборок.

В качестве демонстрации применимости предложенного подхода были рассмотрены две типичные задачи дистанционного зондирования: “Change Detection” и “Small Object Detection”.

Задача “Change Detection” заключается в выявлении изменений между изображениями одной и той же территории, полученными в разные моменты времени, например при строительстве зданий или изменении инфраструктуры (Рис. 2).




Рис.2. Пример синтетически сгенерированной пары изображений и маски изменений для задачи Change Detection.

Задача “Small Object Detection” направлена на обнаружение малых объектов на аэрокосмических изображениях, таких как транспортные средства, которые занимают небольшое количество пикселей и располагаются в плотной городской среде (Рис. 3).

Предлагаемый алгоритм состоит из трех основных этапов:

1. Моделирование виртуальной среды
2. Генерация синтетических данных
3. Автоматическая аннотация.

### 1. Моделирование среды

Городские сцены формируются в “Unreal Engine 5” с использованием процедурной генерации, данных “OpenStreetMap” [8] и инструмента “City-BLD” [9], предназначенного для создания городской планировки (Табл. 1). Такой подход позволяет генерировать топологически правдоподобные структуры застройки и варьировать параметры окружения, включая геометрию зданий, дорожную сеть и элементы городской инфраструктуры. Дополни-

тельно настраиваются освещение, атмосферные эффекты и параметры рендеринга, что обеспечивает реалистичность сцены и полный контроль над ее составом при генерации синтетических данных.

Таблица 1. Характеристики синтетических сцен и статистика генерации изображений.

	City1	City2	City3	OSM City
<b>Размеры (км)</b>	1.5 × 1.5	1.0 × 1.0	1.5 × 1.5	4.0 × 2.5
<b>Количество синтетических изображений</b>	20 000	25 000	50 000	35 000

## 2. Генерация синтетических данных

Процесс генерации данных строится на алгоритмическом переборе состояний виртуальной среды, где положение каждого элемента определяется заданными геометрическими и семантическими ограничениям.

Каждая итерация направлена на создание согласованной пары  $\{I, A\}$ , где  $I$  – синтезированные изображения, а  $A$  – соответствующий им набор высокоточных аннотаций.

### 2.1 Логика размещения объектов и ограничения

Размещение объектов формулируется как задача вероятностного выбора состояний с ограничениями в специальной евклидовой группе  $SE(3)$ , которая представляет собой совокупность преобразований твердого тела. Для каждого экземпляра объекта  $o_i$  его поза определяется вектором состояния  $s_i = (t_i, R_i)$  в мировой системе координат “Unreal Engine 5”, где  $t_i \in R^3$  – вектор смещения, а  $R_i \in SO(3)$  – матрица вращения.

Класс объекта  $L_i$  выбирается стохастически из множества классов  $L$  с использованием взвешенного дискретного распределения  $L_i \sim Discrete(L, w)$ , где  $w$  – настраиваемый вектор весов. Это позволяет контролировать соотношение классов в генерируемом наборе данных.

Позиция  $t_i$  объекта  $o_i$  определяется проекцией луча из виртуальной камеры в сцену, а ориентация  $R_i$  согласуется с поверхностью размещения и, при необходимости, с направлением дорожной траектории.

Для предотвращения некорректных конфигураций выполняется проверка пересечений между объектами и геометрией сцены.

Такой подход позволяет формировать правдоподобные сцены с контролируемым составом и распределением объектов.

## 2.2 Моделирование виртуальной камеры

Камера моделируется как параметризуемый виртуальный сенсор с настраиваемыми внутренними  $K$  (тип проекции, разрешение, FOV и т.д.) и внешними параметрами  $E = [R | t]$ . (положение и ориентация). Внешние параметры определяют наблюдаемую область, служащую опорным элементом для последующего размещения объектов. Использование ортографической проекции позволяет имитировать спутниковую съемку, в то время как перспективная проекция используется для симуляции ракурсов БПЛА.

## 3. Автоматическая аннотация

Одно из преимуществ “Unreal Engine 5” – получение точных аннотации благодаря полной информации о геометрии элементов сцены (Рис. 3). Объекты делятся на отслеживаемые и неотслеживаемые, при этом в разметку включаются только целевые классы. Алгоритм автоматически формирует два типа аннотаций  $A$ : ограничивающие рамки и семантические маски, согласованные с изображением и лишенные ошибок ручного аннотирования.

- **Семантические маски.** Маски формируются автоматически на основе метаданных виртуальной среды. Для повышения качества обучения выполняется постобработка: мелкие фрагменты объектов, возникшие из-за частичных перекрытий, удаляются, если их площадь ниже установленного порога, что минимизирует шум в данных.
- **Ограничивающие рамки.** Для каждого объекта восемь вершин его 3D-ограничивающей рамки  $\{v_j\}_{j=1}^8$  проецируются на плоскость изображения. Итоговая 2D-ограничивающая рамка определяется минимальными и максимальными координатами проекций, ограниченными размерами кадра  $W \times H$ . Это гарантирует точность разметки даже для объектов, частично находящихся за пределами видимости.



Синтезированное изображение

Синтезированное изображение с ограничивающими рамками

Семантическая маска

Рисунок 3. Пример синтетического изображения и автоматически сгенерированных аннотаций для задачи “Small Object Detection”.

## Результаты

Для оценки эффективности предложенного алгоритма были проведены эксперименты на двух задачах дистанционного зондирования: “Change Detection” и “Small Object Detection”. В обоих случаях использовалась схема обучения, при которой модель предварительно обучалась на синтетических данных, после чего выполнялось дообучение на небольшом объеме реальных размеченных данных.

Результаты экспериментов в задачах “Change Detection” и “Small Object Detection” подтверждают эффективность предложенного подхода. Как видно из Рис. 4, использование синтетического предобучения позволяет выявлять дополнительные изменения, которые могут отсутствовать в разметке, но соответствуют визуальному содержанию сцены.




Рисунок 4. Пример Change Detection: (1) изображение  $t_1$  (до изменений), (2) изображение  $t_2$  (после изменений), (3) эталонная сеиантическая маска изменений, (4) предсказание базовой модели, обученной на реальных данных, (5) предсказание модели, предварительно обученной на синтетических данных с последующим дообучением на 1% реальных данных.

Согласно Табл. 2, использование модели “CDLamba” [10] с добавлением синтетических данных (Syn + 10% real) стабильно улучшает метрики на всех датасетах. На LEVIR-CD [11] показатель F1 вырос с 0.861 до 0.882, а IoU – с 0.756 до 0.788. Аналогичный рост зафиксирован на “WHU-CD” [12] (F1 с 0.833 до 0.848) и SYSU-CD [13] (F1 с 0.785 до 0.806), что доказывает высокую обобщающую способность моделей, предобученных на синтетических данных, при дефиците реальных аннотаций.

В задаче “Small Object Detection” (Табл. 3) на датасете “UAVDT” [14] предобучение на синтетических данных обеспечило существенный скачок точности. Для модели “ESOD” [15] значение  $mAP@0.5$  увеличилось с 0.548 до 0.660, а Recall – с 0.583 до 0.687. Для “YOLOv12” [16] + SAHI [17] Precision поднялся с 0.756 до 0.816, а итоговый показатель  $mAP@0.5:0.95$  достиг 0.420, что превосходит результат обучения на полном наборе реальных данных

(0.378). Таким образом, пайплайн на базе “Unreal Engine 5” позволяет эффективно компенсировать нехватку дорогостоящей ручной разметки в дистанционном зондировании.

Таблица 2. Результаты “Change Detection” на LEVIR-CD, WHU-CD и SYSU-CD на модели CDLamba.

Dataset	Training	F1	IoU
<u>LEVIR-CD</u>	<u>100% real</u>	<u>0.899</u>	<u>0.8166</u>
LEVIR-CD	10% real	0.861	0.756
LEVIR-CD	Syn + 10% real	<b>0.882</b>	<b>0.788</b>
<u>WHU-CD</u>	<u>100% real</u>	<u>0.9172</u>	<u>0.8470</u>
WHU-CD	10% real	0.833	0.715
WHU-CD	Syn + 10% real	<b>0.848</b>	<b>0.736</b>
<u>SYSU-CD</u>	<u>100% real</u>	<u>0.8242</u>	<u>0.7009</u>
SYSU-CD	10% real	0.785	0.646
SYSU-CD	Syn + 10% real	<b>0.806</b>	<b>0.675</b>

Таблица 3. Результаты Small Object Detection на UAVDT.

Model	Training	Precision	Recall	mAP@0.5	mAP@0.5:0.95
<u>ESOD</u>	<u>100% real</u>	<u>0.733</u>	<u>0.604</u>	<u>0.563</u>	<u>0.254</u>
ESOD	10% real	0.719	0.583	0.548	0.240
ESOD	Syn + 10% real	<b>0.736</b>	<b>0.687</b>	<b>0.660</b>	<b>0.270</b>
<u>YOLOv12+SAHI</u>	<u>100% real</u>	<u>0.777</u>	<u>0.598</u>	<u>0.682</u>	<u>0.378</u>
YOLOv12+SAHI	10% real	0.756	0.592	0.665	0.375
YOLOv12+SAHI	Syn + 10% real	<b>0.816</b>	<b>0.621</b>	<b>0.707</b>	<b>0.420</b>

## Заключение

В данной работе представлен алгоритм генерации синтетических данных для задач дистанционного зондирования, реализованный на базе движка “Unreal Engine 5”. Разработанный подход позволяет перенести процесс подготовки обучающих выборок в контролируемую виртуальную среду, решая проблему дефицита и высокой стоимости реальных размеченных данных.

Основные результаты работы:

1. Автоматизация моделирования. Использование процедурной генерации и данных “OpenStreetMap” позволило создавать топологически достоверные городские локации большой протяженности, обеспечивая визуальное разнообразие застройки и дорожных сетей.
2. **Управляемая генерация.** Реализована логика размещения объектов с учетом физических и семантических ограничений. Это гарантирует отсутствие пересечений и реалистичное расположение объектов в сцене.
3. **Автоматическая аннотация.** Благодаря прямому извлечению данных из метаданных сцены и параметров виртуальной камеры, алгоритм формирует идеально согласованные пары «изображение-маска» и ограничивающие рамки, исключая ошибки человеческого фактора и обеспечивая точность на пиксельном уровне.

Экспериментальная оценка на задачах “Change Detection” и “Small Object Detection” подтвердила, что предварительное обучение моделей на синтетических данных существенно повышает их обобщающую способность. В условиях ограниченного объема реальных аннотаций предложенный алгоритм позволяет эффективно масштабировать обучающие выборки, подготавливая нейросетевые модели к работе со сложными ракурсами и вариативными условиями съемки. Таким образом, работа подтверждает высокую эффективность использования 3D-симуляций как надежного инструмента для развития систем компьютерного зрения в дистанционном зондировании.

#### ЛИТЕРАТУРА

1. *Chen Y. et al.* Semi-supervised and unsupervised deep visual learning: A survey // “IEEE transactions on pattern analysis and machine intelligence”, Т. 46. №. 3. 2022. СС. 1327–1347.
2. *Zhang W. et al.* Semi-supervised change detection with data augmentation and adaptive thresholding for high-resolution remote sensing images // “Remote Sensing”. Т. 17. № 2. 2025. С. 178.
3. *Ho J., Jain A., Abbeel P.* Denoising Diffusion Probabilistic Models Advances in Neural Information Processing Systems. Curran Associates. 2020.
4. *Khanna S. et al.* Diffusionsat: A generative foundation model for satellite imagery //arXiv preprint arXiv:2312.03606. 2023.
5. *Kong F. et al.* The Synthinel-1 dataset: A collection of high resolution synthetic overhead imagery for building segmentation // “Proceedings of the IEEE/CVF winter conference on applications of computer vision”, 2020. СС. 1814–1823.
6. *Song J. et al.* SynRS3D: A synthetic dataset for global 3D semantic understanding from monocular remote sensing imagery // “Advances in Neural Information Processing Systems”, Т. 37. 2024. СС. 117388–117425.
7. Epic Games. Unreal Engine 5. <https://www.unrealengine.com/>
8. OpenStreetMap contributors. OpenStreetMap. <https://www.openstreetmap.org/>
9. WorldBLD. CityBLD. <https://worldbld.com/>

10. Wu Z. *et al.* CD-lamba: Boosting remote sensing change detection via a cross-temporal locally adaptive state space model // “IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing”. Т. 19. 2026. СС. 4028–4044.
11. Chen H., Shi Z. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection // “Remote sensing”. Т. 12. №. 10. 2020. С. 1662.
12. Ji S., Wei S., Lu M. Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set // “IEEE Transactions on geoscience and remote sensing”. Т. 57. №. 1. 2018. СС. 574–586.
13. Shi Q. *et al.* A deeply supervised attention metric-based network and an open aerial image dataset for remote sensing change detection // “IEEE transactions on geoscience and remote sensing”. Т. 60. 2021. СС. 1–16.
14. Du D. *et al.* The unmanned aerial vehicle benchmark: Object detection and tracking // “Proceedings of the European conference on computer vision (ECCV)”. 2018. СС. 370–386.
15. Liu K. *et al.* ESOD: Efficient small object detection on high-resolution images // “IEEE Transactions on Image Processing”. Т. 34. 2024. СС. 183–195.
16. Tian Y., Ye Q., Doermann D. Yolov12: Attention-centric real-time object detectors //arXiv preprint arXiv:2502.12524. 2025.
17. Akyon F., Altinuc S., Temizel A. Slicing aided hyper inference and fine-tuning for small object detection //2022 IEEE international conference on image processing (ICIP). IEEE, 2022. СС. 966–970.

#### **SYNTHETIC DATA GENERATION PIPELINE FOR REMOTE SENSING TASKS BASED ON UNREAL ENGINE 5**

*K. Surmenelyan, A. Aramyan, O. Hovhannisyanyan, M. Smbatyan,  
V. Poghosyan, A. Malajyan  
Russian-Armenian University*

#### **ABSTRACT**

This paper presents a synthetic data generation pipeline for remote sensing tasks implemented in Unreal Engine 5. The approach is based on procedural modeling of urban environments, stochastic object placement with geometric and semantic constraints, and simulation of virtual camera parameters. Annotations are generated automatically from the 3D scene and include 2D bounding boxes and semantic masks. The proposed pipeline ensures consistency between rendered images and annotations and enables scalable generation of training data for computer vision tasks in remote sensing.

**Keywords:** synthetic data, Unreal Engine, data annotation, remote sensing.