Под эгидой Правительства Российской Федерации
при поддержке Кабинета Министров Республики Татарстан

Under the auspices of the Government of the Russian Federation
With the support of the Cabinet of Ministers of the Republic of Tatarstan

Международный форум KAZAN DIGITAL WEEK – 2026

Proceedings of the International Forum KAZAN DIGITAL WEEK – 2026

I том
Volume I

Казань 2026
Kazan 2026

УДК 004.896(06):656+629+336+338+7.06+61+631
ББК 32.966
М43

Печатается по решению
Ученого совета ОСП «Научный центр безопасности жизнедеятельности
Академии наук Республики Татарстан»

М43 Международный форум KAZAN DIGITAL WEEK – 2026: сборник материалов / Сост.: Р.Ш. Ахмадиева, Р.Н. Минниханов; Под общей ред. действительного члена Академии наук Республики Татарстан, д-ра техн. наук, проф. Р.Н. Минниханова. – Казань: ОСП «Научный центр безопасности жизнедеятельности Академии наук Республики Татарстан», 2026. – Т. 1. – 2478 с.

В сборник включены программные директивы Правительства Российской Федерации, главы Республики Татарстан, оценки ведущими разработчиками и экспертами достижений и перспектив масштабирования и вывода на международные рынки отечественных инновационных наукоемких технологий, отвечающих целям национальных проектов и задач НТР Российской Федерации в современных геополитических и экономических реалиях.

Научные статьи, включенные в сборник, прошли экспертизу ведущих российских специалистов по тематическим направлениям рабочей программы форума, включены в РИНЦ.

Сборник представляет практический интерес для руководителей структур исполнительной власти и государственного управления, специалистов перспективного развития и ИТР предприятий и университетов, организаций социально-гуманитарной сферы.

M43 Proceedings of the International Forum KAZAN DIGITAL WEEK – 2026 / Comp. by R.Sh. Akhmadieva, R.N. Minnikhanov; Under the general editorship of R.N. Minnikhanov, Full Corresponding Member of the Academy of Sciences of the Republic of Tatarstan, Doctor of Technical Sciences, Professor. – Kazan: Separate Structural Subdivision «Scientific Center for Life Safety of the Academy of Sciences of the Republic of Tatarstan», 2026. – V. 1. – 2478 p.

This collection of works from KDW 2026 includes the program directives of the Government of the Russian Federation and the Head of the Republic of Tatarstan, as well as assessments by leading developers and experts regarding the achievements and prospects for scaling up and bringing domestic innovative science-intensive technologies to international markets, meeting the goals of national projects and the tasks of scientific and technological development of the Russian Federation in modern geopolitical and economic realities.

The scientific papers included in this collection have been peer-reviewed by leading Russian experts in the subject areas corresponding to the forum's program and are indexed in the Russian Science Citation Index.

The collection is of practical interest to heads of executive and public administration bodies, specialists in advanced development, engineering and technical personnel of enterprises and universities, and organizations in the social and humanitarian sphere.

© ГБУ «Безопасность дорожного движения», 2026
© State Budget Organization «Road traffic safety», 2026
© ОСП «Научный центр безопасности жизнедеятельности Академии наук Республики Татарстан», 2026
© Separate Structural Subdivision «Scientific Center for Life Safety of the Academy of Sciences of the Republic of Tatarstan», 2026

16+
ISBN 978-5-6056947-6-2

Полученные результаты могут служить основой для дальнейшего совершенствования модели. Учёт дисбаланса классов и настройка параметров позволят повысить качество распознавания редких типов пород и расширить возможности автоматизированной интерпретации каротажных данных.

Список литературы

1. Lithology prediction using K-nearest neighbors (KNN) algorithm: study case in Upper Cibulakan Formation / E. Komara, M. F. Nugraha, M. Rafi, W. Lestari // IOP Conference Series: Earth and Environmental Science. – 2024. – Vol. 1418, № 1. – Art. 012062. – DOI: 10.1088/1755-1315/1418/1/012062.

2. Evaluation of machine learning methods for formation lithology identification: a comparison of tuning processes and model performances / Y. Xie, C. Zhu, W. Zhou [et al.] // Journal of Petroleum Science and Engineering. – 2018. – Vol. 160. – P. 182–193. – DOI: 10.1016/j.petrol.2017.10.028.

3. Support vector machine method, a new technique for lithology prediction in an Iranian heterogeneous carbonate reservoir using petrophysical well logs / M. A. Sebtosheikh, R. Motafakkerfard, M. A. Riahi [et al.] // Carbonates and Evaporites. – 2015. – Vol. 30, № 1. – P. 59–68. – DOI: 10.1007/s13146-014-0199-0.

4. Liu J.-J. Integrating deep learning and logging data analytics for lithofacies classification and 3D modeling of tight sandstone reservoirs / J.-J. Liu, J.-C. Liu // Geoscience Frontiers. – 2022. – Vol. 13, № 1. – Art. 101311. – DOI: 10.1016/j.gsf.2021.101311.

5. Single-well lithofacies identification based on logging response and convolutional neural network / Z. Li, P. Li, Z. Liu, Y. Cui // Journal of Applied Geophysics. – 2022. – Vol. 207. – Art. 104865. – DOI: 10.1016/j.jappgeo.2022.104865.

6. Hochreiter S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9, № 8. – P. 1735–1780. – DOI: 10.1162/neco.1997.9.8.1735.

УДК 004.896:004.932:551.510.4

ГЕНЕРАЦИЯ МУЛЬТИСПЕКТРАЛЬНЫХ СИНТЕТИЧЕСКИХ ДАННЫХ: ПОВЫШЕНИЕ ЭФФЕКТИВНОСТИ ОБУЧЕНИЯ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЕТЕКЦИИ ТОЧЕЧНЫХ ИСТОЧНИКОВ ЭМИССИИ МЕТАНА

Никитин О.В., к.г.н., доцент, ведущий аналитик данных;
ORCID: 0000-0002-6753-0597;
Кузьмин Р.С., директор;
ORCID: 0009-0007-5491-1167;
Кузьмин М.Р, специалист по информационным системам ООО «Экоаудит», г. Москва, Россия;
ORCID: 0009-0005-5186-7266

MULTISPECTRAL SYNTHETIC DATA GENERATION: ENHANCING NEURAL NETWORK TRAINING FOR METHANE POINT SOURCE DETECTION

Nikitin O.V., PhD in Geography, Associate Professor, Lead Data Analyst;
ORCID: 0000-0002-6753-0597;
Kuzmin R.S., director;
ORCID: 0009-0007-5491-1167;
Kuzmin M.R., Information Systems Specialist, Ekoaudit LLC, Moscow, Russia;
ORCID: 0009-0005-5186-7266

Аннотация

Эффективное применение моделей искусственного интеллекта для автоматического мониторинга утечек метана (CH_4) по материалам дистанционного зондирования Земли среднего разрешения (Sentinel-2) ограничено критической нехваткой верифицированных обучающих выборок, особенно применительно к территории Российской Федерации, для которой характерны сложный биогенный фон (водно-болотные территории) и оптическая неоднородность мозаичных ландшафтов, затрудняющие выделение слабого спектрального сигнала CH_4 на фоне альбедо подстилающей поверхности. В работе предложен подход сквозной генерации мультиспектральных синтетических данных путём внедрения физически обоснованных газовых шлейфов в реальные спутниковые снимки, свободные от аномалий. Пространственная геометрия и концентрация CH_4 в факеле рассчитываются на основе стационарной диффузионной модели Гаусса, адаптированной под метеоданные реанализа ERA5-Land, а спектральный отклик в диапазоне SWIR формируется в соответствии с законом Бугера – Ламберта – Бера. На момент подготовки статьи сформирована обучающая выборка объёмом свыше 100 000 размеченных примеров – что больше объёма открытых верифицированных датасетов; обучение нейросетевых моделей на её основе начато и показывает результаты, приближающиеся к целевым метрикам качества. Методика реализуется в рамках создаваемой облачной GeoAI-платформы «Геосфера-Интегра», предназначенной для автоматического мониторинга парниковых газов и природно-климатических рисков промышленных объектов, и закладывает основу для импортонезависимых инструментов экологического мониторинга и контроля парниковых газов.

Ключевые слова: дистанционное зондирование Земли, метан, детекция шлейфов, Sentinel-2, SWIR, синтетические данные, закон Бугера – Ламберта – Бера, модель Гаусса, GeoAI, компьютерное зрение

Abstract

The effective application of artificial intelligence models for automated monitoring of methane (CH_4) leaks using medium-resolution Earth observation data (Sentinel-2) is limited by a critical shortage of verified training samples, particularly for the territory of the Russian Federation. This region is characterized by a complex biogenic background (wetlands) and optical heterogeneity of mosaic landscapes, which hinder the extraction of a weak CH_4 spectral signal from the underlying surface albedo noise. This paper proposes an end-to-end multispectral synthetic data generation approach by embedding physically consistent gas plumes into real, anomaly-free satellite imagery. The spatial geometry and CH_4 concentration within the plume are calculated based on a steady-state Gaussian dispersion model adapted to the ERA5-Land meteorological reanalysis data, while the spectral response in the SWIR range is generated in accordance with the Beer–Lambert–Bouguer law. At the time of publication, a training dataset of over 100,000 labeled patches has been generated, which exceeds the volume of open verified datasets; neural network training on this dataset has commenced and shows results approaching the target quality metrics. The methodology is implemented within the cloud-based GeoAI platform Geosphera-Integra, designed for automated monitoring of greenhouse gases and climate risks at industrial sites, and lays the foundation for sovereign environmental monitoring and greenhouse gas control tools.

Keywords: Earth observation, methane, plume detection, Sentinel-2, SWIR, synthetic data, Beer–Lambert–Bouguer law, Gaussian dispersion model, GeoAI, computer vision

Введение

Сокращение антропогенной эмиссии метана (CH_4) признаётся одной из наиболее эффективных краткосрочных мер по замедлению глобального потепления: потенциал глобального потепления CH_4 на 20-летнем горизонте примерно в 80 раз превышает аналогичный показатель для CO_2 [1]. Вступление в силу Федерального закона № 296-ФЗ и развитие регуля-

торной базы в рамках Сахалинского эксперимента формируют в Российской Федерации (РФ) нормативные предпосылки для перехода к обязательной углеродной отчётности и развитию институтов её независимой верификации [2].

Традиционные методы контроля утечек (пешие и автомобильные обходы, облёты БПЛА) плохо масштабируются на распределённой инфраструктуре протяжённостью в тысячи километров. Альтернативой выступают методы дистанционного зондирования Земли (ДЗЗ): для локализации точечных источников с точностью порядка 200 м наиболее перспективны мультиспектральные данные среднего пространственного разрешения в диапазоне SWIR (20–30 м/пиксель) со спутников Sentinel-2 и Landsat-8/9 [3].

Современные системы детекции смещаются от пороговых алгоритмов к сквозным моделям компьютерного зрения – свёрточным сетям (U-Net) и трансформерам (ViT). Их обучение, однако, сдерживается «голодом данных»: открытые размеченные датасеты (CH4Net, MARS-S2L) относятся преимущественно к регионам аридных зон (Пермский бассейн США, Туркменистан, Северная Африка). Обучение моделей на таких выборках базируется на высоком альбедо и спектральной однородности подстилающей поверхности. Это делает алгоритмы малоэффективными в условиях мозаичных ландшафтов РФ, где высокая оптическая неоднородность территории, в т.ч. вызываемая мозаичностью переувлажненных ландшафтов (водно-болотных комплексов) приводит к обилию ложных срабатываний из-за спектрального шума.

1.1. Существующие подходы к детекции точечных источников

Спутниковые системы наблюдения CH_4 принято разделять на две взаимодополняющие категории [1]: площадные картографы потоков (area flux mappers) – приборы среднего и низкого пространственного разрешения (0,1–10 км), обеспечивающие точную (погрешность <1%) оценку суммарных потоков на региональном и глобальном уровнях (TROPOMI, GOSAT), и точечные визуализаторы источников (point source imagers) – приборы с разрешением менее 60 м, предназначенные для картирования отдельных шлейфов (GHGSat, PRISMA, Sentinel-2, Landsat). Согласно систематическому обзору [1], пороги детекции точечных визуализаторов варьируются на порядки: от 100 кг/ч у GHGSat и Carbon Mapper (за счёт прицельной съёмки и узкой спектральной полосы) до 1800–25 000 кг/ч у многоспектральных приборов Sentinel-2 и Landsat при использовании стандартных методов извлечения сигнала без машинного обучения (где верхняя граница порога обусловлена сильной неоднородностью подстилающей поверхности) [3]. Настоящая работа нацелена на существенное снижение этого порога для Sentinel-2 именно за счёт применения глубокого обучения, что переводит общедоступный многоспектральный инструмент в категорию, сопоставимую по чувствительности с узкоспециализированными коммерческими системами.

До появления методов глубокого обучения детекция утечек CH_4 в данных мультиспектральных спутников опиралась на пороговые алгоритмы сравнения спектральных каналов SWIR. Метод многополосного двухпроходного сравнения (Multi-Band Multi-Pass, MBMP) использует комбинацию каналов B11 и B12 в сопоставлении с архивной (референтной) съёмкой той же сцены для фильтрации вклада подстилающей поверхности [3]; количественная оценка расхода источника при этом обычно выполняется независимо, например методом интегральной массы шлейфа (Integrated Mass Enhancement, IME) [4]. Дальнейшее развитие подхода, основанное на регулярном (каждые 2–5 суток) отслеживании повторных пролётов Sentinel-2 над известными объектами нефтегазовой инфраструктуры, позволило выявлять устойчивые утечки в глобальном масштабе.

Существенным ограничением пороговых методов является достижимый порог чувствительности: по данным систематических обзоров, детекция по данным Sentinel-2 без применения машинного обучения устойчиво работает для утечек мощностью от 1–4 т/ч и выше, при этом наиболее крупные точечные источники («супер-эмиттеры») вносят непропорционально большой вклад в суммарный баланс выбросов. Пороговые методы также чувствитель-

ны к спектрально неоднородным подстилающим поверхностям и требуют, как правило, ручной верификации обнаруженных аномалий.

Переход к сквозным моделям компьютерного зрения, обучаемым на синтетических данных, впервые устранил указанное ограничение на порядок величины: в работе [5] показано, что архитектура на основе архитектур трансформеров (Vision Transformer, ViT), обученная на гауссовых шлейфах, внедрённых по закону Бугера – Ламберта – Бера в реальные сцены Sentinel-2, обеспечивает надёжную детекцию утечек мощностью от 200–300 кг/ч – на порядок ниже порога классических методов, при частоте ложных срабатываний менее 0,03 % на уровне пикселя. Аналогичные результаты по автоматизации детекции шлейфов на основе глубокого обучения получены для гиперспектральных данных PRISMA с применением свёрточных сетей. Настоящая работа опирается на концепцию физически обоснованного внедрения целевого сигнала, адаптированную к территории и ландшафтам РФ.

Цель настоящей работы – представить методику генерации физически обоснованных мультиспектральных синтетических данных для обучения ИИ-моделей детекции утечек CH_4, адаптированную к условиям российских мозаичных ландшафтов, локальным сценам Sentinel-2 и региональным метеорологическим данным. Методика ориентирована на снижение зависимости от дефицита локальных размеченных выборок и создание масштабного обучающего набора для последующей автоматической детекции точечных источников CH_4. Работа выполняется в рамках создания облачной GeoAI-платформы «Геосфера-Интегра», предназначенной для автоматического мониторинга парниковых газов и природно-климатических рисков промышленных объектов.

2. Методология моделирования

Методика основана на интеграции физически обоснованной модели газового шлейфа в реальные («чистые») спутниковые сцены, что позволяет обучать модель распознавать спектральный отклик CH_4 на фоне подлинных текстур ландшафтов РФ. Процесс включает два последовательных этапа: расчёт поля концентраций (перенос примеси в атмосфере) и расчёт радиационного отклика (перенос излучения).

2.1. Расчёт поля концентраций (гауссово приближение)

Для оценки избыточного содержания CH_4 в столбе атмосферы от точечного источника используется интегрированная по вертикали стационарная гауссова модель факела рассеяния примеси:

$$\Delta X_{CH_4}(x,y) = \frac{Q}{\sqrt{2\pi}\cdot u\cdot\sigma_y(x)} \cdot exp\left[-\frac{y^2}{2\sigma_y(x)^2}\right] \quad (1)$$

где Q – массовый дебит источника, выраженный в кг/с (для формирования сбалансированной выборки варьировался в диапазоне от 0,056 до 0,556 кг/с, что соответствует 200–2000 кг/ч); u – скорость приземного ветра, азимут которого задаёт направление переноса шлейфа; $\acute{o}_y(x)$ – горизонтальный коэффициент дисперсии (м), определяемый расстоянием от источника x вдоль оси ветра и классом устойчивости атмосферы по шкале Паскуилла-Гиффорда. Параметры ветра извлекаются из реанализа ERA5-Land для конкретной территории и сезона (модуль CLIMATERA: WIND, свидетельство № 2024614325). Такое аналитическое представление, являющееся результатом точного вертикального интегрирования гауссовой модели факела, исключает необходимость численного интегрирования по слоям атмосферы и напрямую задаёт избыточное содержание газа в столбе (кг/м^2 или пересчитанное в ppm·м). Использование упрощённой формы (1) вместо полной трёхмерной модели обосновано тем, что спутниковый спектрометр регистрирует именно интегральное содержание газа в столбе, а не его вертикальное распределение.

2.2. Расчёт радиационного отклика (закон Бугера – Ламберта – Бера)

Спектральный отклик газовой аномалии в каналах SWIR спутника Sentinel-2 (B11 – 1610 нм, B12 – 2190 нм) моделируется в приближении закона Бугера – Ламберта – Бера с учё-

том геометрии освещения (двукратного прохождения излучения через шлейф). Изменение регистрируемого коэффициента отражения в присутствии газа описывается выражением:

$$R_{syn}(\lambda, x, y) = R_{clear}(\lambda, x, y) \cdot exp\left[-k_{eff}(\lambda) \cdot \Delta X_{CH_4}(x, y) \cdot \left(\frac{1}{cos\theta_0} + \frac{1}{cos\theta}\right)\right], \quad (2)$$

где R_{clear} – значение пикселя на исходном («чистом») снимке; $k_{eff}(\dot{e})$ – эффективный коэффициент поглощения CH_4 для спектрального канала спутника, рассчитанный по спектроскопической базе HITRAN [6]; $\check{c}_0$ и $\check{c}$ – зенитные углы Солнца и визирования спутника соответственно, извлекаемые из метаданных снимка; R_{syn} – синтезированное значение, имитирующее наличие реального шлейфа. Множитель $(1/\cos\check{c}_0 + 1/\cos\check{c})$ представляет собой геометрический фактор воздушной массы (Air Mass Factor, AMF), учитывающий удлинение оптического пути при наклонном падении и регистрации излучения. Для Sentinel-2, работающего преимущественно в надирном режиме, угол визирования $\check{c}$ близок к нулю ($\cos\check{c} \approx 1$), однако учёт зенитного угла Солнца $\check{c}_0$ является критически важным для территорий умеренных и высоких широт, особенно в осенне-весенний период, когда Солнце находится низко над горизонтом и оптический путь в атмосфере существенно удлиняется.

Принципиально важно, что расчёт выполняется на снимках уровня обработки L1C (спектральная яркость на верхней границе атмосферы, Top-of-Atmosphere, TOA), а не L2A (приведённое к поверхности отражение после атмосферной коррекции), так как стандартные алгоритмы атмосферной коррекции Sentinel-2 (Sen2Cor) частично компенсируют полосы газового поглощения, в том числе в интересующем нас диапазоне CH_4 в каналах B11/B12, что исказило бы физически значимый сигнал и сделало бы применение формулы (2) некорректным.

2.3. Алгоритм внедрения и аугментации

Генерация одного обучающего примера реализована в виде стохастического пайплайна: 1) из архива безоблачных сцен Sentinel-2 (уровень обработки L1C) над объектами топливно-энергетического комплекса РФ извлекается случайный патч фиксированного размера (123×123 пикселя, что соответствует линейному размеру ~2,5 км при разрешении 20 м); 2) в случайную точку патча помещается виртуальный точечный источник, инициализируются параметры дебита и ветра; 3) по формуле (1) рассчитывается двумерное поле концентрации $ÄXCH_4$, которое по формуле (2) применяется к каналу B12 (основному спектральному каналу Sentinel-2, чувствительному к поглощению метаном, в соответствии с методологией [5]; вклад канала B11, обладающего значительно меньшей чувствительностью, не учитывается); 4) добавляется контролируемый гауссов шум, имитирующий инструментальную погрешность сенсора; 5) формируется бинарная маска шлейфа (Ground Truth), полностью свободная от ошибок ручной разметки, поскольку строится по известным параметрам синтеза.

Программная реализация пайплайна выполнена на языке Python с использованием библиотек NumPy, Rasterio и SciPy для геопространственной обработки растров и физических расчётов. Конкретные значения гиперпараметров генерации (распределения дебита, высоты источника, классов устойчивости атмосферы) и детали программной реализации отнесены авторами к ноу-хау и в настоящей публикации не раскрываются.

2.4. Количественная оценка дебита источника

Помимо задачи детекции и локализации шлейфа, практическую ценность представляет обратная задача – оценка массового дебита источника Q (кг/ч) по наблюдаемой аномалии столбового содержания CH_4. В систематическом обзоре [1] сопоставлены семь основных методов решения этой задачи, из которых для точечных визуализаторов наиболее распространены три: 1) прямая подгонка гауссовой модели шлейфа, в которой Q определяется аналитически через измеренную аномалию, эмпирический параметр дисперсии $\acute{o}_y(x)$ и скорость ветра u; 2) метод интегральной массы шлейфа (IME), в котором Q рассчитывается через общую массу избыточного CH_4 в шлейфе, характерный линейный размер L и эффективную скорость ве-

тра u_{eff}, параметризуемую по данным крупномасштабного моделирования турбулентности [4]; 3) метод потока через поперечное сечение (CSF), рассчитывающий Q как произведение аномалии концентрации и скорости ветра, проинтегрированное по ширине шлейфа поперёк направления переноса.

Все три метода требуют независимой информации о скорости ветра, что является основным источником погрешности: согласно [1, 4], зависимость от точности данных о ветре ограничивает достижимую точность оценки дебита на уровне около 30 % даже при благоприятных условиях. Разрабатываемый модуль количественной оценки выбросов платформы «Геосфера-Интегра» (свидетельство 2023688757) использует первый из перечисленных подходов – аналитическую инверсию гауссовой модели (1), симметричную по своей структуре генеративной модели, применяемой для синтеза обучающих данных (см. раздел 2.1), с параметрами ветра из реанализа ERA5-Land. Такая симметрия между генеративной и инверсионной частями пайплайна методологически оправдана: модель, использованная для создания обучающей выборки, применяется затем и для интерпретации результатов детекции. Для количественной оценки неопределённости расчёта, вызванной как погрешностью локализации источника, так и погрешностью метеорологических данных, используется ресемплинг методом Bootstrap, что соответствует установленным в отраслевой практике требованиям к отчётности об уровне достоверности инверсионных оценок [1].

Отметим также, что оценка объёма выброса по мгновенному снимку осложняется прерывистостью реальных утечек: по данным авиационных обследований, отдельные точечные источники демонстрируют детектируемую эмиссию в среднем не более 20–26 % времени наблюдения, что обусловливает необходимость многократных повторных наблюдений для надёжной характеризации среднегодового дебита конкретного объекта. Для решения этой задачи в архитектуре платформы «Геосфера-Интегра» предусмотрен модуль накопления временных рядов детекций на базе специализированной СУБД TimescaleDB и их последующего статистического анализа.

3. Формирование датасета и архитектура ИИ

3.1. Стратегия формирования гибридного датасета

На основе описанного пайплайна сформирована сбалансированная выборка со следующими характеристиками:

– источник данных – снимки Sentinel-2 уровня обработки L1C (TOA-отражение, без атмосферной коррекции – см. раздел 2.2) за 2019–2026 гг. над промышленными кластерами Приволжского федерального округа;

– размер патча – 123×123 пикселя (~2,5 км по стороне), сформированный из 10 спектральных каналов в едином пространственном разрешении 20 м;

– балансировка классов – 50 % патчей содержат внедрённый (синтезированный) шлейф (дебит 200–2000 кг/ч), 50 % являются «чистыми» примерами (True Negative) для снижения доли ложных срабатываний, в том числе на фоне сходных по спектральному отклику объектов (грунт, дорожное покрытие);

– объём выборки – на момент подготовки публикации сформировано свыше 100 000 патчей, разделённых в пропорции 70/15/15 на обучающую, валидационную и тестовую подвыборки; генерация продолжается, приоритет отдаётся расширению разнообразия форм подстилающей поверхности и сезонных условий съёмки. Для сравнения, крупнейшие открытые верифицированные датасеты на порядок меньше по объёму и требуют ручной экспертной разметки: CH4Net содержит 925 вручную размеченных масок шлейфов [8], а MARS-S2L – порядка 87 000 изображений с более чем 5500 верифицированными выбросами (UNEP IMEO). Предложенный синтетический пайплайн, не требующий ручной разметки, обеспечивает сопоставимый и уже превосходящий по объёму набор данных при полном контроле баланса классов и параметров источника.

3.2. Архитектуры нейросетевых моделей

В составе GeoAI-ядра платформы для решения задачи попиксельной сегментации шлейфов апробированы три архитектуры компьютерного зрения на базе классической схемы кодировщик-декодировщик U-Net [7], различающиеся реализацией энкодера:

U-Net (базовая свёрточная реализация) – используется в качестве основной модели уровня L2 (детекция шлейфов мощностью свыше 3 т/ч) при сопоставлении с открытым бенчмарком CH4Net, обучение проводится на комбинированной функции потерь Dice + BCE (Dice Loss + Binary Cross-Entropy) для компенсации дисбаланса классов (малая площадь шлейфа относительно фона).

ResUNet – модификация U-Net с заменой энкодера на предобученную свёрточную сеть ResNet-34. Она используется как вспомогательная модель для быстрой проверки рабочих гипотез (изменение состава входных каналов, схемы аугментации, функции потерь) и отладки пайплайна обучения. Использование механизма остаточных связей (residual connections) в сочетании с переносом знаний (transfer learning) от предобученного на больших выборках энкодера обеспечивает кратно более быструю сходимость по сравнению с базовой конфигурацией U-Net. Это позволяет оперативно оценивать эффективность архитектурных изменений и экономить вычислительные ресурсы на итеративных этапах разработки перед постановкой полномасштабного эксперимента.

Гибридная архитектура ViT-энкодер + U-Net-декодер (по типу UNETR) – кодировщик на основе механизма многоголового внимания (Vision Transformer, ViT) заменяет свёрточную часть, а декодирование выполняется последовательными операциями транспонированной свёртки [5]. Глобальный рецептивный охват трансформера теоретически позволяет выделять более слабый спектральный сигнал поглощения на фоне шума подстилающей поверхности, что рассматривается как перспективное направление для снижения порога детекции до целевых 2 т/ч. На данном этапе эта архитектура уступает классической U-Net по соотношению «качество/время обучения» из-за высокой вычислительной сложности механизмов самовнимания (Self-Attention) и требует дальнейшей оптимизации в рамках доступного авторам вычислительного бюджета.

Точные значения гиперпараметров всех трёх архитектур (глубина, число голов внимания, размер эмбеддинга, схема аугментации) и веса обученных моделей составляют коммерческую тайну авторов и не приводятся.

3.3. Целевые метрики качества

Для оценки моделей на тестовой подвыборке приняты метрики, соответствующие уровню бенчмарка CH4Net: IoU (индекс Жаккара) ≥ 0,55; F1-score ≥ 0,55; Recall ≥ 0,80 при Precision ≥ 0,30. Высокий целевой уровень полноты (Recall) при умеренном пороге точности (Precision) обусловлен спецификой задачи: для первичного автоматического скрининга критически важно не пропустить шлейф выброса, в то время как краевые ложноположительные пиксели могут быть отфильтрованы на последующих этапах анализа.

4. Текущие результаты и дальнейшие направления работы

На момент подготовки настоящей публикации полностью реализован и отлажен программный пайплайн генерации синтетических обучающих примеров: автоматизированные модули расчёта гауссова шлейфа, радиационного отклика по закону Бугера – Ламберта – Бера, его внедрения в архивные снимки Sentinel-2 L1C и балансировки классов работают в устойчивом режиме и обеспечили формирование выборки объёмом свыше 100 000 размеченных патчей (раздел 3.1).

Обучение нейросетевых моделей на сформированном датасете начато; на предварительных экспериментах архитектура U-Net приближается к целевым метрикам качества, сопоставимым с мировым бенчмарком CH4Net (раздел 3.3), однако устойчивый результат, готовый к включению в продуктивный контур платформы, пока не получен. Для его достижения в рамках выполнения НИОКР запланированы:

1) дальнейшее наращивание и диверсификация синтетической выборки – в первую очередь по разнообразию форм подстилающей поверхности (различные типы промышленных объектов, грунтов, сельхозугодий) и сезонных условий съёмки (вариации увлажненности почвы, вегетационный период);

2) систематический подбор гиперпараметров архитектур и схем аугментации;

3) сравнительная валидация на открытых датасетах CH4Net и MARS-S2L;

4) дообучение и верификация моделей на данных контролируемых выбросов при появлении доступа к соответствующим наборам.

Применение синтетических данных, внедряемых по описанной методике, по замыслу авторов должно обеспечивать:

1) возможность обучения моделей в условиях фактического отсутствия локальной базы зафиксированных аварийных утечек;

2) снижение доли ложных срабатываний за счёт того, что модель обучается отличать физически обоснованную структуру шлейфа (форма которого определяется полем ветра) от спектрально схожих, но не связанных с газом объектов;

3) распознавание шлейфов мощностью от 2 т/ч с точностью локализации источника не хуже 200 м. Количественное подтверждение этих ожиданий на полном датасете – предмет продолжающейся работы.

Отдельно отметим методологическое ограничение подхода: поскольку синтетические примеры генерируются по детерминированной физической модели, качество обучения напрямую зависит от репрезентативности используемых архивов «чистых» сцен и корректности метеорологического реанализа. Снижение указанных рисков обеспечивается запланированным дообучением моделей на открытых верификационных датасетах CH4Net и MARS-S2L, а также последующей калибровкой по наземным измерениям (модуль INTEGRICAL, свидетельство № 2023688423), что выходит за рамки настоящей статьи.

5. Место методики в иерархической архитектуре платформы «Геосфера-Интегра»

Описанная методика генерации синтетических данных выступает одним из компонентов более широкой, иерархической (четырёхуровневой) архитектуры мониторинга выбросов CH_4, реализуемой в рамках платформы «Геосфера-Интегра» и объединяющей наблюдения разного пространственного масштаба:

L1 (региональный уровень). Оценка суммарного потока CH_4 для города или региона методом масс-баланса по данным TROPOMI (реанализ ERA5 используется для расчёта переноса) с фоновой концентрацией, определяемой статистически [2, 9, 10]; результат – верификация кадастров выбросов (EDGAR, CAMS EAC4).

L2 (детекция крупных шлейфов, свыше 3 т/ч). Попиксельная сегментация шлейфов на снимках Sentinel-2 нейросетевой моделью U-Net (см. раздел 3.2), обучаемой на открытом датасете CH4Net; для первичного скрининга дополнительно применяется пороговый метод MBMP.

L3 (детекция малых утечек, целевой порог 2 т/ч). Задача, на решение которой направлена настоящая работа: снижение порога детекции за счёт обучения на синтетических данных (разделы 2–3) с последующим дообучением на открытом датасете MARS-S2L.

L4 (калибровка и верификация). Пересчёт спутниковых оценок газов-маркеров промышленных выбросов и индикаторов природного биогенного фона (NO_2, CO, HCHO) в приземные концентрации по наземным данным (сеть АСКЗА, УГМС, карбоновый полигон «Карбон-Поволжье») с использованием зарегистрированного алгоритма авторов INTEGRICAL.

Конкретные архитектурные и алгоритмические детали реализации уровней L1–L4, включая гиперпараметры моделей и правила слияния разноуровневых оценок, составляют ноу-хау платформы и в настоящей статье не раскрываются; приведённое описание носит исключительно общеархитектурный характер.

Заключение

В работе представлена методика сквозной генерации мультиспектральных синтетических данных ДЗЗ для обучения нейросетевых моделей детекции утечек CH_4, основанная

на интеграции гауссовой модели рассеяния примеси, метеорологического реанализа ERA5 и закона Бугера – Ламберта – Бера. Предложенный подход снижает зависимость от дефицита локальных верифицированных обучающих выборок, характерную для территории РФ: на его основе уже сформирована выборка, превосходящая по объёму крупнейшие открытые верифицированные датасеты, а обучение моделей сегментации (U-Net) и перспективных трансформерных архитектур (ViT) продолжается с результатами, приближающимися к целевым метрикам качества.

Разработанная методология реализуется в рамках создаваемой облачной GeoAI-платформы «Геосфера-Интегра» для автоматического мониторинга парниковых газов и природно-климатических рисков промышленных объектов, ориентированной на замещение недоступных для российских пользователей зарубежных аналитических систем. Дальнейшее развитие работы в рамках выполнения НИОКР связано с расширением и диверсификацией синтетической выборки, систематическим подбором архитектур и гиперпараметров моделей, а также с верификацией результатов на открытых датасетах и данных контролируемых выбросов.

Список литературы

1. Jacob D.J., Varon D.J., Cusworth D.H. et al. Quantifying methane emissions from the global scale down to point sources using satellite observations of atmospheric methane // Atmospheric Chemistry and Physics. – 2022. – Vol. 22 (14). – P. 9617–9646. – DOI 10.5194/acp-22-9617-2022.

2. Никитин О.В., Степанова Н.Ю., Кузьмин Р.С., Латыпова В.З. Содержание метана в атмосфере Республики Татарстан по данным спутникового мониторинга: глобальные тренды и региональные особенности // Российский журнал прикладной экологии. – 2026. – № 1 (45). – С. 21-35. – DOI 10.24852/2411-7374.2026.1.21.35.

3. Varon D.J., Jervis D., McKeever J. et al. High-frequency monitoring of anomalous methane point sources with multispectral Sentinel-2 satellite observations // Atmospheric Measurement Techniques. – 2021. – Vol. 14 (4). – P. 2771–2785. – DOI 10.5194/amt-14-2771-2021.

4. Varon D.J., Jacob D.J., McKeever J. et al. Quantifying methane point sources from fine-scale satellite observations of atmospheric methane plumes // Atmospheric Measurement Techniques. – 2018. – Vol. 11 (10). – P. 5673–5686. – DOI 10.5194/amt-11-5673-2018.

5. Rouet-Leduc B., Hulbert C. Automatic detection of methane emissions in multispectral satellite imagery using a vision transformer // Nature Communications. – 2024. – Vol. 15 (1). – Art. 3801. – DOI 10.1038/s41467-024-47754-y.

6. Gordon I.E., Rothman L.S., Hargreaves R.J. et al. The HITRAN2020 molecular spectroscopic database // Journal of Quantitative Spectroscopy and Radiative Transfer. – 2022. – Vol. 277. – Art. 107949. – DOI 10.1016/j.jqsrt.2021.107949.

7. Ronneberger O., Fischer P., Brox T. U-Net: convolutional networks for biomedical image segmentation // Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. – 2015. – Vol. 9351. – P. 234–241. – DOI 10.1007/978-3-319-24574-4_28.

8. Vaughan A., Mateo-García G., Gómez-Chova L. et al. CH4Net: a deep learning model for monitoring methane super-emitters with Sentinel-2 imagery // Atmospheric Measurement Techniques. – 2024. – Vol. 17 (9). – P. 2583–2593. DOI 10.5194/amt-17-2583-2024.

9. Nikitin O., Stepanova N., Gubeeva S. et al. Assessment of methane levels throughout a temperate reservoir area using remote sensing data // E3S Web of Conferences. – 2024. – Vol. 555. – Art. 01009. – DOI 10.1051/e3sconf/202455501009.

10. Nikitin O., Stepanova N., Kuzmin R. et al. Estimation of atmospheric methane levels over the Republic of Tatarstan (Russia) territory in 2019-2023 using satellite remote sensing data: effects of anthropogenic and climate drivers // E3S Web of Conferences. – 2024. – Vol. 498. – Art. 02008. – DOI 10.1051/e3sconf/202449802008.