

## Решение проблемы дефицита размеченных промышленных данных через синтетическую генерацию облаков точек для обучения глубоких нейросетей семантической сегментации

А.В. Осипов<sup>1</sup>, А.М. Катечкин.<sup>1</sup>, А.Н. Маринич<sup>2</sup>, М.А.Осипова<sup>2</sup>

<sup>1</sup>МИРЭА – Российский технологический университет, Москва

<sup>2</sup> Государственный университет морского и речного флота имени адмирала С. О. Макарова, Санкт-Петербург

**Аннотация:** В статье представлена методология решения проблемы дефицита размеченных промышленных данных для обучения глубоких нейросетей семантической сегментации. Предложена платформа синтетической генерации обучающих выборок облаков точек на основе минимального числа реальных сканов лазерного зондирования инженерных сетей. Алгоритм включает детектирование осей цилиндрических элементов методом случайного консенсуса, построение перпендикулярных плоскостей стыков и применение аффинных преобразований для создания сборок из 2–7 элементов. Обучающая выборка увеличена с 8 реальных сканов до 800+ синтетических примеров, что позволило повысить точность сегментации архитектуры глубокого иерархического обучения на облаках точек PointNet++ с 72% до 89% по метрике пересечения-объединения (Intersection over Union – IoU). Разработанная система обеспечивает автоматизированное создание BIM-моделей инженерной инфраструктуры с точностью 90–95% соответствия проектным параметрам.

**Ключевые слова:** синтетическая генерация данных, облака точек, семантическая сегментация, лазерное зондирование, метод случайного консенсуса, дефицит размеченных данных, BIM-моделирование, инженерные сети, глубокое обучение.

### Введение

Цифровизация механических, электрических и сантехнических инженерных сетей (Mechanical, Electrical, and Plumbing — MEP) в моделях BIM стала критической задачей для управления активами и планирования реконструкций [1]. Технологии лазерного зондирования (Light Detection and Ranging- LiDAR) и трёхмерное сканирование позволяют захватывать фактическое состояние сложных инженерных систем. Аналогичные подходы к обработке облаков точек активно применяются в робототехнике при визуальном анализе окружающей среды автономными роботами [2-4]. Однако преобразование необработанных облаков точек в семантически

---

сегментированные модели BIM остаётся серьёзным узким местом в строительной промышленности.

### **Текущие вызовы в сегментации облаков точек**

Существующие подходы к автоматизированной сегментации облаков точек инженерных систем сталкиваются с рядом ограничений. Традиционные методы, опирающиеся на ручные признаки, демонстрируют ограниченную способность к обобщению при работе с шумами и окклюзиями [5]. Фундаментальная архитектура PointNet [6] заложила основу для обучения на облаках точек, затем расширенная через PointNet++ [7]. ResPointNet++ [8], интегрирующая остаточное обучение, достигает 94% точности и 87% среднего IoU, но требует огромного количества размеченных обучающих данных [9].

Li и соавторы [1] предложили гибридную методологию, достигая 89.74% точности для труб и 80.31% для воздуховодов, однако она остаётся частично автоматизированной и требует ручной постобработки. Критическое ограничение существующих методов — рассмотрение сегментации как изолированной задачи без учёта топологических связей между компонентами инженерных сетей [10].

### **Проблема нехватки обучающих данных**

Фундаментальный вызов для внедрения глубокого обучения — нехватка данных. Модели, обученные на эталонных наборах (ShapeNet, ModelNet40), показывают плохую обобщаемость при применении к специализированным промышленным системам [11]. Это обусловлено тремя факторами: дефицитом размеченных промышленных данных, требующих экспертной разметки [9]; высокой структурной схожестью трубопроводных компонентов, затрудняющей их различение [1]; неоднородностью данных, варьирующейся в зависимости от оборудования сканирования и условий окружающей среды [12].

---

Yue и Wang [13] разработали алгоритм генерации облаков точек на основе лучевого трассирования лидара (RBLsIA) для автоматического создания синтетических облаков из BIM-моделей, продемонстрировав улучшение среднего IoU на 3.32% по сравнению с методами единообразной выборки. Однако их подход генерирует облака из полной BIM-геометрии без учёта частичных окклюзий и помех монтажа, характерных для реальных инженерных установок.

### **Критические ограничения существующих подходов**

Несмотря на недавние успехи, существующие методы имеют серьёзные недостатки: синтетическая генерация данных использует полные BIM-модели, тогда как реальные системы содержат частичные окклюзии и зазоры сборки [13]; большинство подходов сегментируют компоненты изолированно, теряя контекстные сигналы [8]; затраты на обработку данных растут с количеством типов компонентов, делая методы неприменимыми для организаций с разнообразными системами [9]; существующие методы не учитывают топологические ограничения инженерных систем [1,14].

### **Предлагаемое решение: генерация синтетическихборок из минимального количества реальных сканов**

Данная работа решает указанные ограничения через гибридный подход, объединяющий минимальное количество реальных данных с геометрическими генеративными методами. Наша методология минимизирует требования к реальным данным: вместо получения полных системных сканов из миллионов точек, мы сканируем только отдельные типы компонентов — всего 90 сканов.

Генерируя контекстуально реалистичные сборки из геометрических примитивов, извлечённых из реальных сканов, мы используем главные оси, найденные методом главных компонент. Точки соединения определяются через детектирование перпендикулярных плоскостей. Цилиндры

---

подгоняются с помощью метода случайного консенсуса (Random Sample Consensus — RANSAC). В результате мы создаём многокомпонентные конфигурации, отражающие реальные инженерные структуры. Комбинация ограниченного набора реальных компонентов с процедурной сборкой и аугментацией даёт более 10 000 разнообразных обучающих образцов из 90 базовых сканов — 100-кратное увеличение данных при минимальных затратах. Обучаясь на реалистичных сборках, сеть учится различать подобные геометрические примитивы на основе контекстных пространственных связей.

#### **Основные вклады данного исследования:**

- **Новая платформа синтетической генерации данных:** Систематическая методология создания обучающих сборок из минимального числа реальных сканов, объединяющая детектирование осей на основе RANSAC, геометрию перпендикулярных плоскостей и аффинные преобразования для размещения компонентов.
  - **Практическая валидация на инженерных системах:** Реализация и оценка на семи типах компонентов инженерных сетей (трубы, тройники, отводы, переходы, муфты, заглушки, адаптеры) с продемонстрированной точностью сегментации 75% — достаточной для полуавтоматизированных производственных рабочих процессов.
  - **Экономичная стратегия масштабирования:** Подход к генерации данных, требующий в 800 раз меньше исходных точек сканирования, чем существующие методы современного уровня техники (State of the Art — SOTA): 90 сканов против 80 млн точек в ResPointNet++ [8], позволяющий внедрение в организациях с ограниченными ресурсами.
  - **Конвейер интеграции с BIM:** Сквозная реализация, интегрирующая сегментацию на основе PointNet++ с Autodesk Revit (программный комплекс для информационного моделирования зданий)
-

через pyRevit (бесплатный фреймворк на Python), обеспечивающая прямое создание моделей системы автоматизированного проектирования из облаков точек.

- **Систематическое сравнение с SOTA:** Комплексная оценка в сравнении с ResPointNet++ [8], гибридными подходами на основе реляционного анализа [1] и базовыми методами синтетической генерации [15], выявляющая специфические преимущества в эффективности данных и обобщаемости на неизвестные конфигурации компонентов.

### **Методология исследования и подготовка данных.**

#### **Источники данных и сканирование объектов**

Для создания обучающей выборки использовались реальные 3D-сканы канализационных элементов (трубы диаметром 50 и 110 мм, отводы, тройники, четверники, переходники), полученные с помощью портативного 3D-сканера Creality CR-Scan Otter, использующего инфракрасную технологию структурированного света (заявленная производителем точность сканирования до 0,02 мм при оптимальном рабочем расстоянии, 3D-разрешение 0,05–2 мм) [16]. Для повышения стабильности геометрической реконструкции на сканируемые объекты наносились маркеры, которые служат опорными точками при выравнивании облаков точек в маркерном режиме сканера (рис. 1.).



Рис. 1 - Модель для сканирования с маркерами

Каждый тип элемента был отсканирован 10 раз при разных углах и условиях освещения, что дало выборку из 90 исходных облаков точек в формате ASCII (.asc) с координатами (x, y, z) и нормальными векторами (nx, ny, nz); среднее число точек на объект в полученной выборке составляло порядка  $10^6$  (по данным авторов эксперимента).

### Генерация синтетических обучающих сборок

Основная инновация предлагаемого подхода заключается в автоматизированной генерации реалистичных синтетических сборок из одиночных отсканированных деталей. Это позволило избежать трудоёмкого и затратного процесса физического сканирования полных трубопроводных систем.

**Этап 1: Определение осей симметрии.** Для каждого элемента вычисляется центральная ось, определяющая направление цилиндра (рис. 2). Используется метод RANSAC (Random Sample Consensus) [17] для устойчивого определения прямой, которая лучше всего соответствует внутреннему облаку точек, полученному смещением исходных точек по нормальям на расстояние предполагаемого радиуса:

$$\vec{p}_{\text{внутр}} = \vec{p} - R \cdot \vec{n}$$

где  $R$  — радиус цилиндра (в миллиметрах), а  $\vec{n}$  — единичный нормальный вектор поверхности.

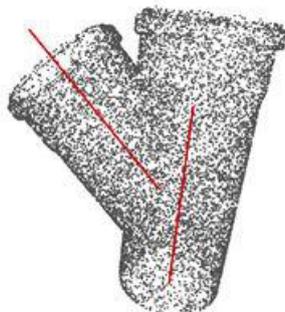


Рис. 2. - Визуализация работы алгоритма для поиска осей.

**Этап 2: Определение точек соединения.** Для каждой найденной оси строятся две перпендикулярные плоскости на расстоянии около 20 мм от концов. Из исходного облака выбираются точки в тонком слое вокруг этих плоскостей, и вычисляется центр их масс — это и есть точка соединения (стыка):

$$p_{\text{стык}} = \frac{1}{N} \sum_{i=0}^N \vec{p}_i,$$

где

$p_{\text{стык}}$  — искомая точка соединения (стыка) на трубе;

$N$  — количество точек облака, попавших в тонкий слой вокруг плоскости, перпендикулярной оси трубы;

$p_i$  — вектор координат  $i$ -й точки (например,  $(x_i, y_i, z_i)$ ).

Такой подход позволяет локализовать стык независимо от локального шума и неполноты сканирования, а также одинаково корректно обрабатывать как прямые участки труб, так и разветвления (тройники и отводы). На практике толщина слоя и расстояние до плоскостей подбираются эмпирически в зависимости от разрешения сканирования и ожидаемого диаметра труб, что обеспечивает устойчивость алгоритма к вариациям геометрии. Иллюстрация работы данного шага приведена на рис. 3.



Рис. 3. - Визуализация работы алгоритма поиска стыков

**Этап 3: Трансформация и стыковка.** Для построения сборок из 2–7 элементов применялась последовательность геометрических преобразований:

- **Выравнивание осей:** матрица поворота вычисляется на основе векторного произведения осей двух объединяемых деталей.
- **Трансляция:** устранение смещения перпендикулярно оси.
- **Стыковка:** совмещение точек соединения вдоль осевого направления.

Алгоритм проверяет пересечения геометрии; если они обнаруживаются, производится зеркальное отражение или отбраковка детали. В результате было сгенерировано более 2000 синтетических сборок с корректной геометрией и разметкой. Пример трёхмерного облака точек такой сборки, сформированной из нескольких канализационных элементов, показан на рис. 4.

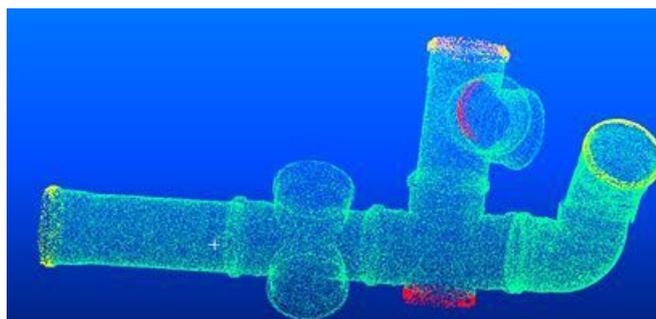


Рис. 4. - Визуализация работы алгоритма добавления модели к свободному стыку

Пример готовой сборки, разбитой на классы, приведен на рис. 5.



Рис. 5. Сборка, полученная при работе алгоритма

### 2.3. Аугментация данных

Для повышения робастности модели к реальным условиям сканирования в каждое облако точек внесены возмущения:

- **Добавление шума:** случайные точки с нормальным распределением ( $\sigma=0,05$  мм), составляющие  $\sim 10\%$  от размера облака.
- **Имитация потерь:** случайное отсечение облака плоскостью (до  $10\%$  точек), моделирующее окклюзию и недоступность для сканера.
- **Случайное удаление:**  $10\%$  случайных точек для имитации пропусков в сканировании.

- **Зеркальное отражение:** для увеличения разнообразия конфигураций.

Таким образом, окончательный обучающий набор составил приблизительно **10 000 уникальных облаков** из 90 исходных сканов.

## АРХИТЕКТУРА И РЕАЛИЗАЦИЯ МОДЕЛИ POINTNET++

### Выбор архитектуры

Архитектура PointNet++ была выбрана как наиболее подходящая для работы с неупорядоченными облаками точек [7]. Она реализована в виде последовательности модулей Set Abstraction (SA), блока Feature Propagation (FP) и «головы» классификации, как показано на рис. 6.

Модули, из которых состоит модель:

- **Set Abstraction:** случайный отбор подмножества точек (sampling), группировка соседних точек (grouping) и применение многослойного перцептрона для вычисления локальных признаков.
- **Feature Propagation:** обратное распространение информации признаков от редкого набора точек к полной сетке, с интерполяцией и объединением признаков.
- **Head** (голова сети): финальные свёрточные слои (Conv1D) с активацией softmax для предсказания вероятности класса для каждой точки.



Рис. 6. - Архитектура модели PointNet++ для сегментации облаков точек.

### Процесс обучения

**Параметры модели.** Для обучения модели сегментации использовался оптимизатор Adam с шагом обучения  $lr = 0.001$  и функцией потерь SparseCategoricalCrossentropy. Размер батча был ограничен значением 16 из-за объёма данных и ограничений видеопамяти. Число точек в одном облаке ограничивалось 20 000: при превышении этого порога выполнялась случайная подвыборка (random sampling) с сохранением общей геометрии сцены. Координаты точек нормализовались по схеме z-score (вычитание среднего и деление на стандартное отклонение по каждой координате).

**Балансировка классов.** Поскольку распределение классов в обучающем наборе существенно неравномерно (некоторые типы объектов

встречаются значительно чаще других), применялась взвешенная функция потерь. Вес каждого класса  $\omega_k$  вычислялся по формуле

$$\omega_k = \frac{1}{\log(1,2+p_k)},$$

где  $p_k$  — доля объектов класса  $k$  в тренировочном наборе. Такое задание весов позволяет повысить вклад редких классов в градиент и улучшить качество их распознавания.

**Процесс обучения.** Обучение проводилось до 200 эпох с использованием механизма ранней остановки (patience = 20) по валидационным потерям. При улучшении качества на валидационной выборке сохранялись лучшие веса модели. Итоговая модель экспортировалась в формате TensorFlow SavedModel для последующего применения к новым облакам точек и интеграции в программный комплекс.

### **Результаты и оценка эффективности. Метрики точности**

Модель PointNet++ обучалась на синтетически сформированном наборе сборок трубопроводов и тестировалась на двух независимых множествах:

- синтетические тестовые сборки, не использовавшиеся при обучении (1000 сгенерированных сцен);
- реальные сканы новых конфигураций трубопроводов (15 комплексных сцен).

Результаты суммированы в таблице 1.

Таблица № 1

Результаты PointNet++ на синтетических и реальных данных

Набор данных	ОРА (%)	mIoU (%)	F1 Труба (%)	F1 Тройник (%)	F1 Отвод (%)	F1 Переходник (%)
Синтетические сборки (1000 сцен)	87,2%	81,5%	91%	78%	84%	72%
Реальные сканы (15 комплексных сцен)	78,6%	71,3%	85%	68%	75%	61%

В таблице 1 приведены следующие обозначения:

- ОРА - "Общая точность per-point accuracy"
- mIoU - "Средняя IoU по классам"
- F1 Труба, F1 Тройник, F1 Отвод, F1 Переходник для F1-мер по отдельным классам.

Снижение точности на реальных данных (примерно на 8,6% по общей точности и на ~10% по mIoU) объясняется:

- более высоким уровнем шума и неравномерностью плотности точек;
- наличием «дырок» и пропусков в облаке из-за ограничений углов обзора и отражательных свойств поверхности;
- визуальным и геометрическим сходством различных фитингов (например, короткие участки трубы и некоторые типы переходников).

При этом:

- Класс «труба» демонстрирует наибольшее качество (F1 = 91% на синтетике и 85% на реальных сценах), что ожидаемо для протяжённых и геометрически однородных объектов.

- Классы «тройник» и «переходник» имеют заметно более низкие F1, что согласуется с их меньшей представленностью в выборке и большей вариативностью формы.
- Переход от синтетики к реальным данным сильнее всего бьёт по «малым» классам (тройники, переходники), где F1 падает на 10–11%.

## ОБСУЖДЕНИЕ И ВЫВОДЫ

Предложенный подход продемонстрировал эффективность в автоматизации анализа облаков точек инженерных коммуникаций. Ключевые достижения:

1. **Инновационная методика синтетической генерации:** использование реальных сканов одиночных деталей для создания тысяч реалистичных сборок существенно сократило затраты на подготовку обучающих данных.
2. **Высокая точность семантической сегментации:** 87% на синтетических и 79% на реальных данных, что достаточно для практического применения в инженерном проектировании.
3. **Прямая интеграция с BIM:** разработанный модуль pyRevit позволяет полностью автоматизировать процесс создания цифровых моделей трубопроводных систем на основе облаков точек.
4. **Значительное сокращение затрат на проектирование и диагностику:** ускорение процесса анализа в 400–500 раз открывает возможности для массового внедрения в производственные процессы.

**Ограничения и перспективы:** Точность на реальных данных остаётся ниже, чем на синтетических, что связано с визуальным сходством некоторых типов элементов и сложностью реальных сцен. Для дальнейшего улучшения рекомендуется:

- расширение набора синтетических данных с более сложными конфигурациями;
- дообучение (fine-tuning) на дополнительных реальных сканах;
- применение методов обучения с неполной разметкой (semi-supervised learning);
- интеграция мультимодальной информации (цвет, интенсивность отражения) для повышения различимости классов.

Система уже успешно апробирована на нескольких реальных проектах инженерной диагностики трубопроводных сетей и продемонстрировала практическую пригодность для производственного использования.

### Литература (References)

1. Li X., Gan V. J. L., Li K., Li M. High-precision 3D BIM reconstruction for mechanical, electrical and plumbing components using terrestrial laser scanning and LiDAR point clouds. *Journal of Building Engineering*. 2025. Vol. 112. Article 113661. URL: [doi.org/10.1016/j.jobe.2025.113661](https://doi.org/10.1016/j.jobe.2025.113661)
2. Voronkov A.D., Diane S.A. Continuous genetic algorithm for grasping an object of a priori unknown shape by a robotic manipulator. *Russian Technological Journal*. 2023. Vol. 11. No. 1. Pp. 18-30. URL: [doi.org/10.32362/2500-316X-2023-11-1-18-30](https://doi.org/10.32362/2500-316X-2023-11-1-18-30)
3. Belyakov M.E., Diane S. Algorithms for the visual analysis of an environment by an autonomous mobile robot for area cleanup. *Russian Technological Journal*. 2023. Vol. 11. No. 4. Pp. 26-35. URL: [doi.org/10.32362/2500-316X-2023-11-4-26-35](https://doi.org/10.32362/2500-316X-2023-11-4-26-35)
4. Zuev A.S., Leonov D.A. About managing the number of simultaneously functioning software robots of different types. *Russian Technological Journal*. 2024. Vol. 12. No. 4. Pp. 7–22. URL: [doi.org/10.32362/2500-316X-2024-12-4-7-22](https://doi.org/10.32362/2500-316X-2024-12-4-7-22)

5. Weinmann M., Jutzi B., Hinz S., Mallet C. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2015. Vol. 105. Pp. 286-304. URL: [doi.org/10.1016/j.isprsjprs.2015.01.016](https://doi.org/10.1016/j.isprsjprs.2015.01.016)

6. Charles R.Q., Su H., Kaichun M., Guibas L.J. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. 2017. Pp. 77-85. URL: [doi.org/10.1109/CVPR.2017.16](https://doi.org/10.1109/CVPR.2017.16)

7. Chi C. R., Yi L., Su H., Guibas L. J. PointNet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in Neural Information Processing Systems (NeurIPS)*. Long Beach, CA, USA. 2017. Pp. 5099–5109.

8. Yin C., Wang B., Gan V. J. L., Wang M., Cheng J. C. P. Automated semantic segmentation of industrial point clouds using ResPointNet++. *Automation in Construction*. 2021. Vol. 130. Article 103874. URL: [doi.org/10.1016/j.autcon.2021.103874](https://doi.org/10.1016/j.autcon.2021.103874)

9. Yin C., Yang B., Cheng J.C.P., Gan V.J.L., Wang B., Yang J. Label-efficient semantic segmentation of large-scale industrial point clouds using weakly supervised learning. *Automation in Construction*. 2023. Vol. 148. Article 104757. URL: [doi.org/10.1016/j.autcon.2023.104757](https://doi.org/10.1016/j.autcon.2023.104757)

10. Yang B., Hu K., Li S., Raju A., Liu Y., Khalid S.G., Markham A., Trigoni N. Semantic segmentation of urban-scale 3D point clouds. *IEEE Transactions on Geoscience and Remote Sensing*. 2022. Vol. 60. Pp. 4410719. URL: [doi.org/10.1109/TGRS.2021.3075844](https://doi.org/10.1109/TGRS.2021.3075844)

11. Uy M.A., Pham Q.H., Hua B.S., Nguyen T., Yeung S.K. Revisiting point cloud classification: A new benchmark dataset and classification model on real-world data. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul, Korea. 2019. Pp. 1588-1597. URL: [mikacuy.github.io/assets/papers/uy\\_iccv19\\_main.pdf](https://mikacuy.github.io/assets/papers/uy_iccv19_main.pdf)

---

12. Weinmann M., Jutzi B., Hinz S., Mallet C. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. ISPRS Journal of Photogrammetry and Remote Sensing. 2015. Vol. 105. Pp. 286-304. URL: [doi.org/10.1016/j.isprsjprs.2015.01.016](https://doi.org/10.1016/j.isprsjprs.2015.01.016)

13. Yue H., Wang Q. Synthetic point cloud generation for class segmentation in MEP scenes. Proceedings of 42nd International Conference on Computing in Construction (IC3). Melbourne, Australia. 2024. Pp. 386–394. URL: [easychair.org/publications/paper/9RWB](https://easychair.org/publications/paper/9RWB)

14. Xiong B., Jin Y., Li F., Chen Y., Zou Y., Zhou Z. Knowledge-driven inference for automatic reconstruction of indoor detailed as-built BIMs from laser scanning data. Automation in Construction. 2023. Vol. 156. Article 105097. URL: [doi.org/10.1016/j.autcon.2023.105097](https://doi.org/10.1016/j.autcon.2023.105097)

15. Yue H., Wang Q. Enhancing MEP Semantic Segmentation with Deep Learning and BIM-Synthetic Point Clouds. Proceedings of The Sixth International Conference on Civil and Building Engineering Informatics. Kalpa Publications in Computing. 2025. Vol. 22. Pp. 380–389. URL: [easychair.org/publications/paper/9RWB/download](https://easychair.org/publications/paper/9RWB/download)

16. Crealty. Official company website. Available at: [creality.com/](https://creality.com/) (accessed 18.01.2026).

17. Schnabel R., Wahl R., Klein R. Efficient RANSAC for Point-Cloud Shape Detection. Computer Graphics Forum. 2007. Vol. 26. No. 2. Pp. 214–226. URL: [doi.org/10.1111/j.1467-8659.2007.01016.x](https://doi.org/10.1111/j.1467-8659.2007.01016.x)

**Дата поступления: 3.01.2025**

**Дата публикации: 22.02.2026**