

## ГИБРИДНЫЙ ПОДХОД ОБРАБОТКИ ОБЛАКОВ ТОЧЕК ПОМЕЩЕНИЙ НА ОСНОВЕ ГЕОМЕТРИЧЕСКОЙ СЕГМЕНТАЦИИ, КЛАСТЕРИЗАЦИИ И ГЛУБОКОГО ОБУЧЕНИЯ

О.И. Христодуло (*o-hristodulo@mail.ru*)  
А.Я. Байчугуров (*trappistt@yandex.ru*)  
Л.Р. Мухаметдинова (*2mllr4@mail.ru*)

Уфимский университет науки и технологий, Уфа

Предложен гибридный подход к обработке облаков точек внутренних помещений, интегрирующий алгоритмы геометрической сегментации и плотностной кластеризации с нейросетевой классификацией на основе архитектуры PointNet. Данная комбинация обеспечивает эффективное распознавание структурных элементов и объектов сцены при существенном сокращении требований к объему размеченных данных за счет перехода от поточечной семантической сегментации к классификации предварительно сегментированных кластеров.

**Ключевые слова:** облако точек, трёхмерная сцена, сегментация, кластеризация, нейронная сеть PointNet, классификация, семантическая сегментация.

### Введение

В статье исследуется научно-практическая проблема несоответствия между возможностями автоматизированной обработки облаков точек внутренних пространств зданий и требованиями к точности пространственных моделей, что выражается в необходимости ручной коррекции значительного объема результатов автоматического распознавания объектов [Феттер и др., 2022]. Проблема особенно актуальна при построении планов помещений, где требуется доработка человеком из-за ограниченности алгоритмов в идентификации элементов внутренней структуры (стен, окон, дверей, мебели) из-за фрагментарности данных лазерного сканирования, шумов и наложения объектов.

Исследование выполняется в рамках проекта «Геоинформационная система Уфимского Университета науки и технологий». Учитывая, что университет состоит из 18 корпусов, разработка метода автоматизированной обработки облаков точек внутренних помещений является актуальной. Разрабатываемый метод оптимизирован для вузовских сред с ключевыми ограничениями: несовместимостью с современными нейросетевыми архитектурами (CUDA 9.0) и требованиями к ресурсоэффективности [Рахимова и др., 2013].

Актуальность работы обусловлена необходимостью преодоления фундаментального противоречия между возрастающими требованиями к точности пространственных моделей помещений и ограничениями существующих методов. Свёрточные нейронные сети неэффективны при обработке нативных 3D-данных из-за потери геометрических признаков при 2D-проекции [Терещенко и др., 2021]. Технические барьеры вузовских систем включают устаревшие версии CUDA, несовместимые с современными архитектурами, и требования к легковесности моделей для интеграции в ресурсоограниченные системы. Кроме того, алгоритмы демонстрируют низкую устойчивость к фрагментарности данных SLAM-сканирования и шумам кластеризации, характерным для мобильных съёмок помещений.

В данной работе предлагается гибридный подход, сочетающий геометрические алгоритмы сегментации, кластеризации (RANSAC и DBSCAN) и нейросетевую классификацию объектов с помощью модели PointNet, напрямую работающей с облаками точек. Метод работает поэтапно: RANSAC используется для выделения крупных плоскостных структур, DBSCAN – для плотностной кластеризации оставшихся объектов, а PointNet – для последующей классификации полученных кластеров по типу объекта (стол, стул, доска и др.) [Гура и др., 2023].

В отличие от существующих методов, основанных на end-to-end семантической сегментации (PointNet, PointNet++ [Qi et al., 2017]) или чисто алгоритмических подходах (например, [Xie et al., 2020]), предлагаемый гибридный подход впервые комбинирует геометрическую сегментацию, плотностную кластеризацию и изолированную классификацию объектов PointNet. Это позволяет устранить ключевые ограничения:

- Для нейросетевых методов: зависимость от огромных размеченных датасетов и чувствительность к шуму.
- Для алгоритмических методов: неспособность распознавать неметрические объекты сложной формы.
- Новизна подхода заключается в каскадной обработке данных, где кластеризация DBSCAN после RANSAC выполняет роль «предсегментации», снижая требования к данным для PointNet.

Разметка данных при этом всё ещё необходима, так как модель PointNet требует обучающего набора данных с метками классов. Однако, в отличие от задач семантической сегментации, где требуется размечать каждую точку в облаке, для задачи классификации кластеров достаточно обозначить одну метку на объект, что существенно упрощает процесс подготовки данных для обучения модели [Новикова и др., 2024].

Также проведено сравнение предложенного метода с прямой семантической сегментацией на базе PointNet, что позволяет оценить преимущества и ограничения гибридного подхода в реальных условиях. Полученные результаты обеспечивают снижение трудозатрат при создании цифровых планов помещений за счёт комбинированной обработки данных (геометрическая сегментация, кластеризация и классификация кластеров) и могут быть интегрированы в информационные, а также геоинформационные системы для автоматизации инвентаризации объектов внутренних пространств с точностью до 82.6% по взвешенной F1-мере.

## **1. Алгоритмы сегментации, кластеризации RANSAC и DBSCAN**

### **1.1. Подготовка и фильтрация данных**

В качестве тестового набора данных была выбрана трёхмерная сцена, представленная в виде облака точек в формате PLY. Исходные данные получены из открытого набора SketchUp 3D. Выбрано помещение, которое содержит 681270 облаков точек.

Перед применением сегментации данные проходят предобработку:

- Фильтрация выбросов – применяется метод Statistical Outlier Removal, основанный на анализе расстояний до ближайших соседей и удалении аномально удалённых точек [Волкова, 2013]. Это позволяет уменьшить шум и повысить точность последующей сегментации.
- Воксельная фильтрация – делит пространство на равномерные ячейки, оставляя в каждой только одну точку, что снижает плотность облака и вычислительные затраты при сохранении геометрической структуры трёхмерной сцены [Василенко, 2024]. В нашем случае, размер вокселя выбран 0,6 см на основе среднего расстояния до ближайшего соседа в облаке точек.

### **1.2. Сегментация плоскостей методом RANSAC**

Алгоритм RANSAC (RANdom SAMple Consensus) позволяет устойчиво находить геометрические модели в данных, содержащих шум и выбросы. В контексте внутренних помещений RANSAC используется для выделения плоских структур: стен, пола, потолка.

Процедура работы RANSAC:

1. Случайный выбор минимального числа точек (обычно трёх) для построения плоскости.
2. Подсчет числа точек, находящихся вблизи этой плоскости (инлайеров).
3. Итерации повторяются фиксированное количество раз.

Найденные инлайеры удаляются из облако, и RANSAC повторяется на остатке – это называется многошаговой RANSAC-сегментацией (Multi-Order RANSAC) [Соколова и др., 2014].

Однако RANSAC выделяет только плоскости без учёта связности точек, что может приводить к ошибкам.

### 1.3. Кластеризация DBSCAN

Для устранения недостатков RANSAC и кластеризации оставшихся точек применяется алгоритм кластеризации DBSCAN (Density-Based Spatial Clustering of Applications with Noise), который не требует заранее заданного числа кластеров и устойчив к выбросам [Шафроненко и др., 2011].

Алгоритм работает на основе двух параметров:

- Радиус поиска соседей;
- Минимальное число кластеров для формирования кластера.

DBSCAN используется на двух этапах:

- После RANSAC: точки, принадлежащие найденной плоскости, дополнительно кластеризуются, и сохраняется только самый плотный связный сегмент, остальные – исключаются или передаются в повторную обработку.
- На остатке облака: DBSCAN выделяет кластеры точек сложной формы, например, объекты мебели, оборудования и др.

Такой каскадный подход позволяет гибко выделять как плоскости, так и произвольные объекты в помещении. Параметры алгоритмов в нашей работе подбирались вручную на основе эмпирической оценки качества сегментации с помощью визуализации. Есть методы для автоматического подбора параметров, например, радиус поиска DBSCAN можно подобрать с помощью графика расстояний до  $k$ -го соседа, выбрав значение радиуса в точке перегиба [Шафроненко и др., 2011].

Для визуального отображения результатов сегментации и кластеризации на рис. 1 каждому кластеру присвоен цвет из циклической палитры «tab20». Вследствие конечности цветового пространства (20 дискретных значений) при количестве кластеров, превышающем 20, происходит повторное использование цветов.



Рис. 1. Сегментированные и кластеризованные облака точек с помощью методов RANSAC и DBSCAN

## 2. Архитектура PointNet

PointNet – это нейросетевая архитектура, способная напрямую обрабатывать неупорядоченные облака точек [Qi et al., 2017]. Её ключевая особенность – использование общих (shared mlp) слоёв и симметричной функции агрегации (max pooling), что позволяет получить инвариантные к порядку точек признаки.

Общая структура сети включает следующие компоненты:

- Input transform (T-Net) – это обучаемый модуль для выравнивания облака точек.
- Shared MLP: извлекает локальные признаки.
- Feature transform (T-Net): оптимизирует пространство признаков.
- Max Pooling: симметричная функция агрегации, извлекающая глобальные признаки.

На рис. 2 представлена классическая архитектура PointNet (для классификации и семантической сегментации).

В качестве нейросетевого классификатора выбрана архитектура PointNet. Альтернативные архитектуры, такие как PointNet++ [Qi et al., 2017], не применялись в исследовании ввиду их **технической несовместимости** с требованиями проекта:

- Системы обработки данных университета работают на устаревшей версии CUDA (9.0), несовместимой с фреймворками для PointNet++.
- Техническое задание предусматривало использование легковесных моделей для интеграции в геоинформационные системы с ограниченными вычислительными ресурсами.



Рис. 2. Схема архитектуры PointNet

Несмотря на это, предложенный гибридный подход демонстрирует конкурентоспособную точность.

### 3. Гибридный подход обработки облака точек

Гибридный подход обработки облака точек сочетает алгоритмические методы (RANSAC, DBSCAN) и нейросетевую классификацию (PointNet) для обработки облака точек внутренних помещений. Такой метод особенно полезен для трёхмерных сцен, содержащих как регулярные структуры (стены, пол, потолок), так и объекты сложной формы (мебель, оборудование). На рис. 3 представлена схема гибридного подхода обработки облака точек, включающая этапы предобработки, сегментации, кластеризации и классификации.



Рис. 3. Схема процесса обработки облака точек гибридным методом

Для классификации объектов применен датасет ModelNet10 [Wu et al., 2015], содержащий 10 классов мебели и сантехники в формате полигональных сеток. Данные предварительно нормализовались, а облака точек генерировались из полигонов, пример одного из файлов датасета показан на рис. 4.




Рис. 4

В роли функции потерь была выбрана NLLLoss (Negative Log Likelihood Loss), которая измеряет расхождение между предсказанным распределением вероятностей и истинным распределением – формула (3.1) [Гура и др., 2023]

$$NLLLoss(x, y) = -\log(x_y), \tag{3.1}$$

На основании построенной матрицы ошибок (рис. 5) выявлено, что модель демонстрирует наибольшую ошибку классификации при распознавании объектов класса «комод», относя их к классу «письменный стол».




Рис. 5. Матрица ошибок классификации

В представленном гибридном подходе, рассчитана взвешенная F1-мера по формуле (3.2) [Горячкин и др., 2021], учитывающая дисбаланс классов. Данная метрика демонстрирует средневзвешенное значение F1-меры по всем классам, где веса определяются количеством экземпляров каждого класса.

$$Weighted-F1 = \sum_{i=1}^C w_i \times F1_i, \quad (3.2)$$

Применение гибридного метода обработки облаков точек позволило получить сегментированную, кластеризованную трёхмерную сцену с идентифицированными объектами, представленную на рис. 6. Объект «раковина» ошибочно отнесена к другому классу, так как такой класс отсутствует в обучающем наборе ModelNet10.



Рис. 6. Сегментированная и кластеризованная трёхмерная сцена с распознанными объектами

Для сравнения эффективности предложенного метода была реализована семантическая сегментация с помощью PointNet. Этот метод требует полной точечной разметки облаков, что делает его более ресурсоёмким и чувствительным к шуму и неоднородности плотности точек [Христодуло и др., 2023].

Для валидации семантической сегментации использован Stanford 3D Indoor Spaces Dataset (S3DIS) [Armeni et al., 2016], включающий 272 помещения с 13 классами объектов (стены, окна, мебель и др.). Выбор обусловлен репрезентативностью для задач распознавания интерьеров.



В качестве функции потерь PointNet для семантической сегментации выбрана IoU (Intersection over Union) – это метрика, используемая для оценки качества сегментации или обнаружения объектов. Она измеряет степень перекрытия между предсказанным и истинным объектом.

Также составлена матрица ошибок, представленная на рис. 7, где видно, что модель лучше всего распознаёт классы: пол, стена, потолок.

	ceiling	floor	wall	beam	column	window	door	table	chair	sofa	bookcase	board	stairs	clutter
ceiling	1130353	1006	20254	2147	0	33	1192	165	0	0	0	0	5647	2240
floor	0	950743	2813	0	0	0	448	0	0	0	0	7	0	2292
wall	43879	16236	1242804	22237	2504	42480	86924	5609	1009	0	7700	3462	6503	29456
beam	33090	0	67994	107685	0	262	24587	0	0	0	942	0	0	14740
column	1418	1679	70139	1061	0	4833	65939	365	24	0	157	0	0	1352
window	117	0	102418	628	0	42451	27	237	20	0	59	0	854	2873
door	0	5253	126206	9380	84	1432	159118	234	189	0	3088	0	2	3892
table	0	7350	30593	0	0	777	4303	180107	30250	174	7841	0	39	61469
chair	0	17734	9752	0	0	0	7952	51586	94371	402	2083	31	372	31147
sofa	0	1516	2499	0	0	5	57	2339	9900	8172	0	0	1143	3043
bookcase	0	5019	112571	2761	1549	3860	34532	9985	4544	135	33182	110	0	25812
board	0	145	90778	0	0	644	1240	150	223	0	1176	7014	0	4602
stairs	0	227	7383	0	0	0	0	0	0	0	0	0	0	3901
clutter	115225	17038	195365	16614	591	5433	32871	41972	14273	802	25907	1382	6973	196756

Рис. 7. Матрица ошибок семантической сегментации

Для оценки эффективности гибридного подхода был применен комплекс метрик, адаптированных к специфике задач, включая Overall Accuracy (OA) для доли верно классифицированных точек, mean Intersection over Union (mIoU) для оценки границ объектов и Weighted Fscore для взвешенной  $F_1$ -меры с коррекцией дисбаланса классов. Сопоставлены результаты гибридного метода (RANSAC+DBSCAN+PointNet) для классификации кластеров и PointNet для поточечной семантической сегментации – табл. 1.

Таблица 1

Метод	OA	mIoU	$F_1$
Гибридный подход	0.89	0.83	0.8528
PointNet	0.78	0.33	0.6524

Анализ результатов показал, что гибридный метод демонстрирует значительное преимущество с метрикой mIoU, равной 0.83, благодаря предварительной сегментации с использованием RANSAC и DBSCAN, которая формирует семантически однородные кластеры и снижает влияние шумов и фрагментарности данных. В то же время базовая PointNet имеет ограниченные возможности с метрикой mIoU, равной 0.33, из-за накопления ошибок при поточечной обработке и чувствительности к неоднородной плотности точек.

График демонстрирует превосходство гибридного метода по метрике mIoU рис. 8.




Рис. 8. Сравнение методов по метрике mIoU

Семантическая сегментация трёхмерной сцены с использованием модели PointNet показана на рис. 9. Каждая точка окрашена в соответствии с предсказанным классом. Как видно из изображения, модель корректно сегментирует крупные структурные элементы, такие как стены и пол, однако объекты меньших размеров не распознаются, что свидетельствует о недостаточной чувствительности модели к маловыраженным элементам сцены.




Рис. 9. Семантически сегментированная трёхмерная сцена

С помощью сравнительного анализа выделены преимущества гибридного подхода обработки облака точек:

- Снижение требований к размеченным данным.
- Интерпретируемость результатов.
- Гибкость.

Также выявлены недостатки подхода:

- Зависимость от ручного подбора параметров.
- Ручной отбор кластеров, получившихся в результате геометрической сегментации и кластеризации.
- PointNet анализирует кластеры изолированно, что может приводить к ошибкам в случаях неправильной кластеризации объектов.

## Заключение

В работе предложен гибридный подход к обработке облаков точек внутренних помещений, сочетающий методы RANSAC, DBSCAN и нейросетевую архитектуру PointNet. Это повысило эффективность обработки и распознавания объектов при минимальных требованиях к разметке. Однако PointNet имеет ограничения в анализе локальных геометрических особенностей, снижая точность для сложных объектов [Христоудло и др., 2023a]. Рассматривается интеграция с иерархическими архитектурами, такими как PointNet++, для улучшения анализа пространственных контекстов. Экспериментально подтверждена точность классификации 82.6% (F1-мера) при сокращении трудозатрат. Метод применим для автоматизированного создания цифровых планов. Дальнейшие исследования направлены на адаптацию для онлайн-обработки данных и интеграции с мультимодальными источниками.

## Список литературы

- [Феттер и др., 2022] Феттер М.Г., Евтушенко С.И. Проблемы применения автоматической расстановки элементов при построении информационной модели трубопроводных систем здания по облакам точек // Строительство и архитектура. – 2022. – №. 2. – С. 71-75.
- [Терещенко и др., 2021] Терещенко С.Н., Перов А.А., Осипов А.Л. Особенности применения предобученных свёрточных нейронных сетей к задачам стегаанализа графических изображений // Автометрия. – 2021. – № 4. – С. 98-105. – doi: 10.15372/AUT20210412.
- [Рахимова, 2013] Рахимова А.Р., Абдуллин А.Х. Аспекты внедрения геоинформационных технологий в Вузе // \*Перспективы развития информационных технологий\*. – 2013. – № 12.
- [Христоудло и др., 2023] Христоудло О.И., Вохминцев А.В., Романов М.А. Семантическая классификация и сегментация археологических объектов на основе слияния детектора объектов и 3DEF // Труды Международной российской конференции по автоматизации, RusAutoCon 2023. – 2023. – С. 122-127.
- [Гура и др., 2023] Гура Д.А., Болтовнина О.С. Применение существующих алгоритмов по классификации и кластеризации точек лазерного отражения (K-MEANS, DBSCAN, SVM) для решения задач территориального планирования // Вестник ДГТУ. Технические науки. – 2023. – № 1.

- [Новикова и др., 2024] Новикова А.Ю., Кан Е.Н. Автоматизация процессов обновления данных BIM-моделей объектов капитального строительства // ЭПИ. – 2024. – № 2.
- [Соколова и др., 2014] Соколова М.Ю., Костюхина М.А. Применение информационных технологий в научных исследованиях // Экономика и социум. – 2014. – № 2-5(11).
- [Шафроненко и др., 2011] Шафроненко А.Ю., Волкова В.В., Бодянский Е.В. Адаптивная кластеризация данных с пропущенными значениями // Радиотехника, информатика, управління. – 2011. – № 2(25).
- [Волкова, 2013] Волкова Л.Л. Метод подавления шума в изображениях на основании кратномасштабного анализа // Инженерный журнал: наука и инновации. – 2013. – № 6(18). – URL: <https://cyberleninka.ru/article/n/metod-podavleniya-shuma-v-izobrazheniyah-na-osnovanii-kratnomasshtabnogo-analiza> (дата обращения: 30.05.2025).
- [Василенко, 2024] Василенко Д.В. Разработка алгоритма классификации плотных облаков точек на примере городской застройки // Вестник СГУГиТ (Сибирского государственного университета геосистем и технологий). – 2024. – № 6.
- [Горячкин и др., 2021] Горячкин Б.С., Чечнев А.А. Анализ чувствительности метрик бинарной классификации к дисбалансу данных // E-Scio. – 2021. – № 4(55).
- [Христовуло и др., 2023a] Христовуло О.И., Вохминцев А.В., Полякова Л.Ю. Система картографирования для интерпретации зон разломов в сейсмических данных на основе автокодировщика и генеративно-сопоставительных сетей // Материалы Международной конференции по промышленной инженерии, приложениям и производству, ICIEAM 2023. – 2023. – С. 1003-1007.
- [Wu et al., 2015] Wu Z., Song S., Khosla A., Yu F., Zhang L., Tang X., Xiao J. 3D ShapeNets: A deep representation for volumetric shapes // \*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)\*. – 2015. – P. 1912-1920. – doi: 10.1109/CVPR.2015.7298801.
- [Armeni et al., 2016] Armeni I., Sener O., Zamir A. R., Jiang H., Brilakis I., Fischer M., Savarese S. 3D semantic parsing of large-scale indoor spaces // \*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)\*. – 2016. – P. 1534-1543. – doi: 10.1109/CVPR.2016.170.
- [Rusu et al., 2009] Rusu R. B., Blodow N., Beetz M. Fast point feature histograms for object recognition (RANSAC/DBSCAN) // \*IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)\*. – 2009. – Vol. 31, No. 8. – P. 1451-1465. – doi: 10.1109/TPAMI.2008.58.
- [Qi et al., 2017] Qi C.R., Su H., Mo K., Guibas L.J. PointNet: deep learning on point sets for 3D classification and segmentation // \*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)\*. – 2017. – P. 77-85. – doi: 10.1109/CVPR.2017.16.
- [Dai et al., 2018] Dai A., Chang A. X., Savva M., Halber M., Funkhouser T., Nießner M. ScanNet: richly-annotated 3D reconstructions of indoor scenes // \*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)\*. – 2018. – P. 5828-5839. – doi: 10.1109/CVPR.2017.261.