

# ЗЕМЛЕУСТРОЙСТВО, КАДАСТР И МОНИТОРИНГ ЗЕМЕЛЬ

УДК [004.032.26:621.373]+332.3  
DOI 10.33764/2411-1759-2024-29-4-135-144

## Подбор параметров обучения нейронной сети PointNext при сегментации точек лазерного отражения для государственного мониторинга земель

*Р. А. Дьяченко<sup>1</sup>, Д. А. Гура<sup>1,2</sup>, Д. А. Беспятчук<sup>1</sup>, С. В. Самарин<sup>3</sup>✉*

<sup>1</sup>Кубанский государственный технологический университет,  
г. Краснодар, Российская Федерация

<sup>2</sup>Кубанский государственный аграрный университет,  
г. Краснодар, Российская Федерация

<sup>3</sup>Московский физико-технический институт, г. Долгопрудный, Российская Федерация

e-mail: sierghiei222@mail.ru

**Аннотация.** Статья посвящена исследованию применения искусственных нейронных сетей в качестве метода обработки данных лазерного сканирования при проведении государственного мониторинга земель. Важнейшей характеристикой нейронной сети является показатель точности сегментации, поэтому целью настоящего исследования является подбор наилучших параметров обучения на примере искусственно сгенерированного облака точек лазерного отражения для повышения качества модели нейронной сети PointNext при проведении государственного мониторинга земель. В работе проанализированы результаты обучения и оценена точность полученной модели. Как результат, выявлены наилучшие параметры обучения для получения максимальной точности при обучении нейронной сети PointNext. Полученные параметры позволят уменьшить сроки проведения государственного мониторинга земель при реализации государственной программы по приватизации земельных участков из государственной собственности.

**Ключевые слова:** искусственно сгенерированные облака точек, PointNet++, гаражная амнистия, управление муниципального контроля, земельный надзор

### Для цитирования:

*Дьяченко Р. А., Гура Д. А., Беспятчук Д. А., Самарин С. В.* Подбор параметров обучения нейронной сети PointNext при сегментации точек лазерного отражения для государственного мониторинга земель // Вестник СГУГиТ. – 2024. – Т. 29, № 4. – С. 135–144. – DOI 10.33764/2411-1759-2024-29-4-135-144

### Введение

В век высоких технологий во многие сферы жизни общества стали активно внедряться искусственный интеллект и нейронные сети. Несомненно, к этому привело развитие социума, как следствие, возникла потребность в автоматизации различных процессов с целью экономии времени и средств как в условиях повседневной жизни, так и на предприятии.

Искусственный интеллект нашел применение в строительстве [1], в решении задач территориального планирования, также применяется для целей контроля наполнения Единого государственного реестра недвижимости (ЕГРН) и может быть применен в обработке информации, полученной при государственном мониторинге земель [2].

На территории муниципального образования город Краснодар земельный контроль

за соблюдением требований земельного законодательства в отношении объектов земельных отношений организует и осуществляет управление муниципального контроля (УМК, Управление). В полномочия Управления входит надзор за соблюдением требования наличия разрешения на строительство и соблюдения указанных в них параметров, а также контроль соответствия объектов капитального строительства (ОКС) предельным параметрам разрешенного строительства, установленных правилами землепользования и застройки (ПЗЗ).

При осуществлении государственного контроля за объектами муниципальной собственности Управление ведет проверку соблюдения требований законодательства и условий договоров, а также:

- в рамках межведомственных запросов осуществляет осмотры земельных участков;
- составляет акты визуальных осмотров использования земельных участков на территории города;
- ведет реестр объектов самовольного строительства [3].

Мониторинг Управления проводится классическим способом без внедрения каких-либо вспомогательных средств, например, беспилотных авиационных систем (БАС) [4], компьютерного зрения или искусственных нейронных сетей (ИНС). В случае нехватки специалистов, осуществляющих надзор, Управление обращается за помощью в смежные структуры, например Роскомнадзор.

Авторы статьи считают, что внедрение автоматизированных процессов распознавания будет полезным при реализации Федерального закона (О внесении изменений в отдельные законодательные акты Российской Федерации : федер. закон от 05.04.2021 № 79-ФЗ. – URL: <http://www.consultant.ru>. – Текст: электронный) («О гаражной амнистии») [5]. Закон о гаражной амнистии не только позволяет оформить права собственности на гараж, но и учитывает возможность предоставления земельного участка под таким гаражом в собственность от государства.

На опыте последних трех лет реализации Программы по приватизации земельных

участков из государственной собственности в городе Краснодар граждане ждут свои постановления о согласовании земельных участков в собственность от 6 до 16 месяцев, однако срок оказания такой муниципальной услуги регламентирован и составляет 1 месяц. Это обусловлено тем, что в настоящий момент в работе департамента муниципальной собственности (ДМС) находится порядка 7 000 обращений граждан, которые не могут быть отработаны в такие короткие сроки.

Сотрудники ДМС направляют запросы по каждому делу в несколько структур для получения их согласования по предоставлению земельного участка. Тенденция такова, что не все структуры отвечают быстро и без замечаний. После получения ответов по запросам правовой департамент проверяет все материалы дела, выносит замечания и отправляет на доработку, пока все требования законодательства не будут соблюдены.

Сюда же относится и УМК, которые должны выезжать на место испрашиваемого земельного участка, чтобы проверить наличие гаража, его этажность, убедиться, что гараж капитальный, и подготовить заключение, срок актуальности которого составляет 3 месяца. Исходя из средних сроков реализации гаражной амнистии, можно судить, что УМК выезжает на осмотр по каждому объекту в среднем несколько раз за время рассмотрения дела.

Таким образом, авторы статьи предлагают к решению этой проблемы использование ИНС PointNext для обработки данных, полученных при проведении государственного мониторинга за гаражами для собственных нужд.

В данной статье предлагается применение сверточной ИНС PointNext, которая является модификацией нейросети PointNet++ и была создана для работы с облаками точек лазерного отражения для последующей сегментации, классификации и идентификации трехмерных данных [6]. Наиболее важным этапом применения ИНС является ее обучение, и от того, насколько качественно обучена ИНС, зависит дальнейшая эффективность ее работы. На качественное обучение ИНС влияют правильно подобранные параметры, позволяющие получить наибольшую точность результатов [7]. По этой причине, подбор наилучших

параметров обучения выбранной ИНС PointNext является целью настоящего исследования.

Указанная цель может быть достигнута путем решения следующих задач:

- анализ архитектуры PointNext;
- подбор параметров обучения, которые влияют на показатели точности обучения;
- выбор настроек, способствующих повышению точности;
- подготовка соответствующих выводов.

### Методы и материалы

Для проведения экспериментов с обучением модели PointNext сегментации объектов в облаках точек был использован набор данных, сгенерированный интеллектуальной системой Terra\_Maker [8], предложенный учеными Кубанского государственного универси-

тета. Набор данных состоит из точек лазерного отражения участка территории размером 1 000 на 1 000 метров, с общим количеством точек более 4,7 млн, более 500 объектов недвижимости. Визуальное представление искусственно сгенерированного набора данных в облаке точек представлено на рис. 1, а фрагмент структуры сгенерированного набора данных – в табл. 1.




Рис. 1. Визуальное представление набора данных облака точек

Таблица 1

Структура файла с набором данных (фрагмент)

<i>X</i> (координата)	<i>Y</i> (координата)	<i>Z</i> (координата)	<i>R</i> (цветовая компонента)	<i>G</i> (цветовая компонента)	<i>B</i> (цветовая компонента)	<i>L</i> (метка)
178,500	295,000	-15,1400	237	0	0	2
178,500	295,000	-15,1300	242	0	0	2
178,500	296,000	-15,1800	251	0	0	2
178,500	296,000	-15,1500	241	0	0	2
178,500	297,000	-15,1100	245	0	0	2
178,500	297,000	-15,3100	256	0	0	2
178,500	298,000	-15,3100	239	0	0	2
178,500	298,000	-15,1900	221	0	0	2
178,500	299,000	-15,2700	228	0	0	2


### Архитектура сети PointNext

В рамках работы рассматривается архитектура PointNext, которая не только обладает высокой производительностью, но и обеспечивает более быстрое выполнение задач, чем другие современные методы.

Модель PointNet++ модернизирована до современной PointNext за счет введения остаточных связей, инвертированного дизайна узких мест и сепарабельного многочлена MLP [9–11] для эффективного масштабирования модели, что как следствие улучшило производительность в различных сопоставительных

анализах на основе эталонных показателей (бенчмарках) [12].

PointNext задумывалась как новая версия PointNet++ с производительностью обучения для сохранения и совершенствования территориальной привязки к ней единицы площади земельного участка (SOTA) [13]. На данный момент можно сказать, что она превосходит SOTA в различных задачах, таких как классификация объектов, семантическая сегментация и сегментация частей, и демонстрирует лучшую производительность по сравнению с другими моделями (рис. 2).

Рис. 2. Архитектура сети *PointNext*

Архитектура *PointNext* основана на архитектуре типа U-Net [14] с использованием кодера и декодера. Кодер абстрагирует признаки облаков точек с помощью блоков абстракции множеств, таких как сабсемплирующий слой (SA), слой группировки, MLP и слой агрегации [15,16]. Декодер постепенно интерполирует абстрагированные признаки с помощью аналогичного числа блоков распространения особенностей. Слои SA формулируются с помощью уравнения, включающего слой агрегации и общий MLP для извлечения признаков. Внутри этой архитектуры используется одномасштабная группировка, включающая один SA-блок на этап. PointNet++ используется в качестве базовой архитектуры [17,18].

Принцип работы нейронной сети PointNext при выполнении сегментации облаков точек выглядит следующим образом: выбирается область с точками из файла с набором данных, от первой взятой точки в пункте один до близлежащих точек строятся определенные геометрические фигуры, после чего нейронная сеть анализирует облако точек и при обнаружении фигур с одинаковой геометрией относит их к одному классу.

### Экспериментальные установки

Для экспериментов применялось следующее аппаратное и программное обеспечение.

1. Использование мощностей среды выполнения GoogleColab.

2. Локальная станция для машинного обучения с характеристиками:

- операционная система Linux Ubuntu 22.04.2;

- язык программирования Python 3, дистрибутив Anaconda;

- фреймворк машинного обучения PyTorch.

При генерации набора данных (dataset) всем точкам были присвоены метки, размеченные на пять классов: земля, крыши зданий, низкая растительность, средняя растительность, высокая растительность.

Обучение модели проводилось в среде выполнения Google Colab, в которую был загружен искусственно сгенерированный набор данных. Были заданы параметры обучения, которые подбирались экспериментально, а именно, определено количество точек для одного обучаемого образца, а также задан такой важный параметр, как размер сетки и количество эпох.

Эксперименты были проведены дважды, с тремя входными каналами  $X Y Z$ , как представлено в табл. 2, а также с шестью входными каналами ( $X Y Z R G B$ ), как представлено в табл. 3.

### Результаты и обсуждение

В рамках данной научной статьи было проведено 12 экспериментов, в ходе которых между циклами менялись параметры размера сетки ( $G_s$  – grid size) на 25, 50, 75, и 100 м, а также число точек ( $N_p$  – number points) на 2 500, 5 000 и 7 500, количество эпох во всех экспериментах было задано 100. В исследовании применялась функция потерь CrossEntropy loss, оптимизатор Adam optimizer, экспоненциальное убывание скорости обучения (Step Decay). Результаты экспериментов представлены в табл. 2.

Таблица 2

Результаты обучения нейросети архитектуры PointNext с тремя входными каналами X Y Z

Номер подхода	Gs (размер сетки)	Np (число точек)	Loss (значение функции потерь)	Acc (точность)
1	25	2500	0,39638516306877136	0,9998888788668888
2	25	5000	0,39971911907196045	0,9993453333333333
3	25	7500	0,3976341784000397	0,9994333333333383
4	50	2500	0,4060260057449341	0,9987677777655454
5	50	5000	0,41495752334594727	0,9973576773333367
6	50	7500	0,4120860695838928	0,9991333333333333
7	75	2500	0,4120315909385681	0,9989876577777777
8	75	5000	0,42169877886772156	0,9979532456322323
9	75	7500	0,43434420228004456	0,9904222222345444
10	100	2500	0,4078928530216217	0,9985323456543454
11	100	5000	0,40941357612609863	0,9981344333333455
12	100	7500	0,41230452060699463	0,9969333333333333

Таблица 3

Результаты обучения нейросети архитектуры PointNext с шестью входными каналами X Y Z R G B

Номер подхода	Gs (размер сетки)	Np (число точек)	Loss (значение функции потерь)	Acc (точность)
1	25	2500	0,3991994261741638	0,9899999788668888
2	25	5000	0,3988911907196045	0,9873456788765433
3	25	7500	0,39811253547668457	0,9796666666666667
4	50	2500	0,4987260057449341	0,9764345754333454
5	50	5000	0,40985752334594987	0,9693576773333367
6	50	7500	0,41987654395838928	0,9755513399833333
7	75	2500	0,41098765400000681	0,9765437657777777
8	75	5000	0,48765077886772156	0,9788953245322323
9	75	7500	0,40083442022800446	0,9764785222345444
10	100	2500	0,4078928530216217	0,9765442346543454
11	100	5000	0,49977357612609863	0,9876444433333455
12	100	7500	0,48756543998765678	0,9767693333333333

Лучший результат зафиксирован в первых трёх экспериментах, так как их точность стремится к единице, но лучшим результатом из этих трёх будет являться тот, что получен при количестве точек в одном обучающем образце, равном 2 500 при размере сетки 25. При этом по данным табл. 2 можно выявить следующую зависимость параметров обучения

для наилучшей точности – чем меньше сторона сетки и взято меньше точек в облаке, тем обучение ИНС будет наиболее эффективно.

На рис. 3 представлен график значений точности обучения (Acc – ассигасу, вычисляемая по confusion matrix) по эпохам обучения. Параметры обучения были следующие: число точек – 2 500, размер сетки – 25, число эпох – 100.




Рис. 3. График значений точности по эпохам обучения

Пример работы сети на трех каналах представлен на рис. 4. Слева представлены наборы данных четырех участков исходного облака точек, а справа – модели предсказанного облака точек соответствующего эксперимента. На рисунках видно, что полученные в процессе обучения модели идентичны, что подтверждается данными табл. 2 и говорит о том, что поставленная в работе цель, а именно – подбор наилучших параметров обучения, была достигнута.









Номер цикла	Исходное облако точек	Предсказанное облако точек
1		
2		
3		
4		

Рис. 4. Пример работы нейронной сети PointNext с тремя заданными каналами

С целью исследования возможности улучшения качества модели были проведены ещё 12 экспериментов с шестью входными каналами  $XYZRGB$  с учетом прежних переменных, которые были подобраны.

В результате проведенных экспериментов выявлена следующая закономерность – чем меньше признаков задано в обучении, тем лучше точность обучения, так как соответствие предсказанного облака точек реальному получается точнее. Результаты исследования с шестью входными каналами показывают, что точность повторно проведенных 12 экспериментов также стремится к единице и нисколько не страдает при большем количестве заданных признаков.

### **Заключение**

В заключение можно сделать вывод, что для облаков точек, обученных без RGB, наилучшая точность получилась равной 0.9998, для облаков точек, обученных с RGB получена наилучшая точность, равная 0.9899. Таким образом, при использовании в наборах данных информации с RGB и без RGB, где количество данных меньше, точность сопоставима.

Результаты обучения представлены в табл. 2 и 3, такие показатели точности, как 0.9998, сильно приближены к единице и практически равняются ей, что обусловлено тем, что набор данных, использованный в исследовании, является искусственно сгенерированным, а облака точек – эталонными, то есть без наличия искажений и шумов.

Проведенные эксперименты позволили определить лучшие настройки параметров

обучения модели. В результате проделанной работы было выявлено, что предпочтительным параметром обучения является применение наименьшего количества точек, так как точность в этом случае выше, а эффективность лучше. Данный тип ИНС можно использовать на моделях, где отсутствует информация о цвете при полученном, нормальном уровне точности, что подтверждает повышение качества модели. Лучшие параметры обучения получены при меньшей стоимости сетки и меньшем количестве точек в облаке, нейронная сеть в таком случае обучается наиболее эффективно. В рамках данной работы при проведении экспериментов с ИНС с искусственно сгенерированным набором данных были найдены наилучшие параметры для обучений нейросети PointNext.

Нейросеть с выявленными параметрами позволит эффективно проводить сегментацию объектов на земельных массивах с целью последующей их идентификации [19]. В дальнейших исследованиях планируется применение воздушного лазерного сканирования с последующей камеральной обработкой при помощи данной ИНС для выявления незаконного строительства, распознавания расстояний и длин линий с целью контроля за соблюдением предельных параметров строительства: этажности, отступов от границ земельных участков.

### **Благодарности**

Исследование выполнено при финансовой поддержке Кубанского научного фонда в рамках научно-инновационного проекта № НИП-20.1/22.16.

### **БИБЛИОГРАФИЧЕСКИЙ СПИСОК**

1. Рыбкина А. М., Демидова П. М., Коробицына Е. С. Методы интеллектуального анализа территории при строительстве объектов дорожного транспорта // Вестник СГУГиТ. – 2023. – Т. 28, № 4. – С. 138–149. – DOI 10.33764/2411-1759-2023-28-4-138-149.
2. Черных Е. Г. Организационно-управленческая система регионального мониторинга земель с целью пространственного развития урбанизированных территорий // Вестник СГУГиТ. – 2023. – Т. 28, № 5. – С. 163–172. – DOI 10.33764/2411-1759-2023-28-5-163–172.
3. Пархоменко Д. В., Пархоменко И. В. Принципы и методика исследования соответствия самовольной постройки градостроительным регламентам // Вестник СГУГиТ. – 2022. – Т. 27, № 6. – С. 169–178. – DOI 10.33764/2411-1759-2022-27-6-169-178.

4. Гура Д. А., Марковский И. Г., Ряскин А. А. Использование беспилотных летательных аппаратов при осуществлении государственного земельного надзора // Вестник СГУГиТ. – 2022. – Т. 27, № 5. – С. 138–146.
5. Гура, Д. А., Марковский И. Г., Пшидаток С. К. Методика мониторинга объектов недвижимости с помощью трехмерного лазерного сканирования в специфике городских земель // Геодезия и картография. – 2021. – Т. 82, № 4. – С. 45–53. – DOI 10.22389/0016-7126-2021-970-4-45-53.
6. Гура Д. А., Дьяченко Р. А., Бойко Е. С., Левченко Д. А. Настройка обучения моделей при классификации и сегментации облаков точек // Искусственный интеллект и принятие решений. – 2024. – № 1. – С. 92–102. – DOI 10.14357/20718594240108.
7. Qian, Guocheng Li, Yuchen Peng, Houwen Mai, Jinjie Hammoud, Hasan Abed Al Kader Elhoseiny, Mohamed & Ghanem, Bernard. PointNeXt: Revisiting PointNet++ with Improved // Training and Scaling Strategies. – 2022.
8. Левченко Д. А., Бойко Е. С. Генератор цифровых данных геоточек искусственных территорий «Terra\_Maker»: св-во о государственной регистрации программы для ЭВМ, № 2023610228.
9. Guocheng Qian, Hasan Hammoud, Guohao Li, Ali Thabet, and Bernard Ghanem. Assanet: An anisotropic separable set abstraction for efficient point cloud representation learning // Advances in Neural Information Processing Systems (NeurIPS). – 2021. – 34.
10. Mikaela Angelina Uy, Quang-Hieu Pham, Binh-Son Hua, Duc Thanh Nguyen, and Sai-Kit Yeung. Revisiting point cloud classification: A new benchmark dataset and classification model on real-world data. // In Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). – 2019.
11. Guohao Li, Matthias Müller, Guocheng Qian, Itzel C. Delgadillo, Abdullellah Abualshour, Ali K. Thabet, and Bernard Ghanem. Deepgcns: Making gcns go as deep as cnns. // IEEE transactions on pattern analysis and machine intelligence (T-PAMI) – PP. – 2021.
12. Глинский А. В., Новиченко Е. В., Ткачев М. С., Савенков В. М., Теплякова А. Р., Захарочкина Н. А., Бирюков Р. Н., Акобян Л. В. Программа семантической сегментации с учетом данных, получаемых с камер и лидаров : св-во о регистрации программы для ЭВМ 2022663627, 18.07.2022.
13. Fanfan WU, Feihu YAN, Weimin SHI, Zhong ZHOU, 3D scene graph prediction from point clouds // Virtual Reality & Intelligent Hardware – 2022. – Vol 4, No 1. — P. 76–88.
14. Liyao Tang, Yibing Zhan, Zhe Chen, Baosheng Yu, and Dacheng Tao. Contrastive boundary learning for point cloud segmentation. // In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2022.
15. Xiaohan Ding, Xiangyu Zhang, Yizhuang Zhou, Jungong Han, Guiguang Ding, and Jian Sun. Scaling up your kernels to 31x31: Revisiting large kernel design in cnns // In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) – 2022.
16. Abdullah Hamdi, Silvio Giancola, and Bernard Ghanem. Mvtn: Multi-view transformation network for 3d shape recognition. In Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) – P. 1–11. – 2021.
17. Reba M., Seto K. C. A systematic review and assessment of algorithms to detect, characterize, and monitor urban land change. // Remote Sensing of Environment – 242. – 2020. – P. 174–181. – DOI 10.1016/j.rse.2020.111739.
18. Xiaohua Zhai, Alexander Kolesnikov, Neil Houlsby, and Lucas Beyer. Scaling vision transformers. // In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) – P. 12104–2022 – 12113.
19. Колесников А. А. Анализ методов и средств искусственного интеллекта для анализа и интерпретации данных активного дистанционного зондирования // Вестник СГУГиТ. – 2022. – Т. 27, № 3. – С. 74–94. – DOI 10.33764/2411-2022-27-3-74-94.

## Об авторах

Роман Александрович Дьяченко – доктор технических наук, профессор, директор Института компьютерных систем и информационной безопасности.

Дмитрий Андреевич Гура – кандидат технических наук, доцент кафедры кадастра и геоинженерии Кубанского государственного технологического университета, доцент кафедры геодезии Кубанского государственного аграрного университета.

Дарья Андреевна Беспятчук – магистр специальности Прикладная информатика.

Сергей Владимирович Самарин – аспирант физико-технической школы радиотехники и компьютерных технологий.

Получено 22.04.2024

© Р. А. Дьяченко, Д. А. Гура, Д. А. Беспятчук, С. В. Самарин, 2024

## Selection of training parameters of PointNext neural network for segmentation of laser reflection currents during state land monitoring

R. A. Dyachenko<sup>1</sup>, D. A. Gura<sup>1,2</sup>, D. A. Bespyatchuk<sup>1</sup>, S. V. Samarin<sup>3</sup>✉

<sup>1</sup> Kuban State Technological University, Krasnodar, Russian Federation

<sup>2</sup> Kuban State Agrarian University, Krasnodar, Russian Federation

<sup>3</sup> Moscow Institute of Physics and Technology, Dolgoprudny, Russian Federation

e-mail: sierghiei222@mail.ru

**Annotation.** The article is devoted to the research of artificial neural networks application as a method of laser scanning data processing in the process of state land monitoring. The most important characteristic of a neural network is the segmentation accuracy index, so the purpose of this study is to select the best training parameters on the example of artificially generated laser reflection point cloud to improve the quality of the PointNext neural network model for state land monitoring. The results of training are analyzed and the accuracy of the obtained model is evaluated. As a result, the best training parameters for obtaining the maximum accuracy in training the neural network PointNext are revealed. The obtained parameters will allow to increase the terms of the state monitoring of lands at realization of the state program on privatization of land plots from the state property.

**Keywords:** artificially generated point clouds, PointNet++, garage amnesty, municipal control department, land supervision

## REFERENCES

1. Rybkina, A. M., Demidova, P. M., & Korobitsyna, E. S. (2023) Methods of intellectual analysis of the territory in the construction of road transport facilities. *Vestnik SGUGiT [Vestnik SSUGT]*. P. 138–149 [in Russian].
2. Chernykh, E. G., (2023) Organizational and managerial system of regional land monitoring for the purpose of spatial development of urbanized territories *Vestnik SGUGiT [Vestnik SSUGT]* P. 163–172 [in Russian].
3. Parkhomenko, D. V., & Parkhomenko, I. V. (2022) Principles and methodology of research on the compliance of unauthorized construction with urban planning regulations *Vestnik SGUGiT [Vestnik SSUGT]*, P. 169–178 [in Russian].
4. Gura, D. A., Markovskii, I. G., & Ryaskin, A. A. (2022) The use of unmanned aerial vehicles in the implementation of state land supervision *Vestnik SGUGiT [Vestnik SSUGT]*. P. 138–146 [in Russian].
5. Gura, D. A., Markovskii, I. G., & Pshidatok, S. K. (2021) Methodology for monitoring movable objects using three-dimensional laser scanning in the specifics of urban areas. *Geodeziya i kartografiya. [Geodesy and cartography]*. P. 45–53 [in Russian].

6. Gura, D. A., D'yachenko, R. A., Boiko, E. S., & Levchenko, D. A. (2024) Setting up model training in the classification and segmentation of point clouds *Iskusstvennyi intellekt i prinyatie reshenii. [Artificial intelligence and decision-making.]* P. 92–102 [in Russian].
7. Qian, Guocheng Li, Yuchen Peng, Houwen Mai, Jinjie Hammoud, Hasan Abed Al Kader Elhoseiny, Mohamed & Ghanem, Bernard. (2022) PointNeXt: Revisiting PointNet++ with Improved. *Training and Scaling Strategies*.
8. Levchenko, D. A., & Boyko, E. S. *Patent RF No 2023610228*. IP Russian Federation.
9. Guocheng Qian, Hasan Hammoud, Guohao Li, Ali Thabet, & Bernard Ghanem. (2021) Asanet: An anisotropic separable set abstraction for efficient point cloud representation learning. *Advances in Neural Information Processing Systems (NeurIPS)*.
10. Mikaela Angelina Uy, Quang-Hieu Pham, Binh-Son Hua, Duc Thanh Nguyen, & Sai-Kit Yeung. (2019) Revisiting point cloud classification: A new benchmark dataset and classification model on real-world data. *In Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*.
11. Guohao Li, Matthias Müller, Guocheng Qian, Itzel C. Delgadillo, Abdullhah Abu-alshour, Ali K. Thabet, & Bernard Ghanem. (2021) Deepgens: Making gens go as deep as cnns. *IEEE transactions on pattern analysis and machine intelligence (T-PAMI)*.
12. Glinsky, A.V., Novichenko, E. V., Tkachev, M. S., Savenkov, V. M., Teplyakova, A. R., Zarochkina, N. A., Biryukov, R. N., & Hakobyan, L. V. *Patent RF No 2022663627*. IP Russian Federation.
13. Fanfan, WU, Feihu, YAN, Weimin, SHI, & Zhong, ZHOU. (2022) 3D scene graph prediction from point clouds. *Virtual Reality & Intelligent Hardware* P. 76–88.
14. Liyao Tang, Yibing Zhan, Zhe Chen, Baosheng Yu, & Dacheng Tao. (2022) Contrastive boundary learning for point cloud segmentation. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
15. Xiaohan Ding, Xiangyu Zhang, Yizhuang Zhou, Jungong Han, Guiguang Ding, & Jian Sun. (2022) Scaling up your kernels to 31x31: Revisiting large kernel design in cnns *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
16. Abdullah Hamdi, Silvio Giancola, & Bernard Ghanem. (2021) Mvtn: Multi-view transformation network for 3d shape recognition. *In Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, P. 1–11.
17. Reba M., & Seto, K. C. (2020) A systematic review and assessment of algorithms to detect, characterize, and monitor urban land change. *Remote Sensing of Environment* 242. P. 174–181.
18. Xiaohua Zhai, Alexander Kolesnikov, Neil Houlsby, & Lucas Beyer. (2022) Scaling vision transformers. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* P. 12104–12113.
19. Kolesnikov, A. A. (2022) [Analysis of artificial intelligence methods and tools for the analysis and interpretation of active remote sensing data] *Vestnik SGUGiT [Vestnik SSUGT]*, P. 74–94. DOI 10.33764/2411-2022-27-3-74-94 [in Russian].

### Author details

*Roman A. Dyachenko* – D. Sc., Professor, Director of the Institute of Computer Systems and Information Security.

*Dmitry A. Gura* – Ph. D., Associate Professor of the Department of Cadastre and Geoengineering Kuban State Technological University, Associate Professor of the Department of Geodesy Kuban State Agrarian University.

*Bespyatchuk D. Andreevna* – Master's degree in Applied Informatics.

*Samarin S. Vladimirovich* – Ph. D. Student, Physics and Technology School of Radio Engineering and Computer Technologies.

Received 22.04.2024

© R. A. Dyachenko, D. A. Gura, D. A. Bespyatchuk, S. V. Samarin, 2024