

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ТЕЛЕКОММУНИКАЦИИ
INFORMATION TECHNOLOGY AND TELECOMMUNICATIONS

УДК 303.732.4



DOI: 10.21822/2073-6185-2023-50-4-158-165 Оригинальная статья /Original article

Анализ архитектуры нейронной сети PointNet

Л.А. Щенявская¹, Д.А. Гура^{1,2}, Р.А. Дьяченко¹

¹Кубанский государственный технологический университет,

¹350072, г. Краснодар, ул. Московская, 2, Россия,

²Кубанский государственный аграрный университет,

²350044, г. Краснодар, ул. имени Калинина 13, Россия

Резюме. Цель. Большинство исследователей преобразуют данные облаков точек в обычные трехмерные воксельные сетки или коллекции изображений, что делает данные излишне объемными и вызывает проблемы при их обработке. Целью исследования является проведение анализа архитектуры нейронной сети PointNet. **Метод.** Применен единый подход к решению различных задач трехмерного распознавания, начиная от классификации объектов, сегментации деталей и заканчивая семантическим анализом сцены. **Результат.** Проведен сравнительный анализ классификации 2d и 3d объектов, подробно изучены слои и функции, благодаря которым происходит классификация. Рассмотрен тип нейронной сети, которая непосредственно использует облака точек, что хорошо учитывает инвариантность перестановок точек во входных данных. Определено, что сеть обеспечивает унифицированную архитектуру для приложений, начиная от классификации объектов, сегментации деталей и заканчивая семантикой сцены. Для семантической сегментации входными данными может быть, как отдельный объект из сегментации области детали, так и небольшая часть 3D-сцены. Нейронная сеть, которая широко используется для редактирования растровых изображений, графического дизайна и цифрового искусства представляет собой глубокую архитектуру облака точек под названием PointNet. **Вывод.** Представлена новая глубокая архитектура облака точек PointNet. Для задачи классификации объектов облако входных точек непосредственно выбирается из формы или предварительно сегментируется из облака точек сцены. Для получения виртуальной модели реального мира используются нейросетевые решения, основанные на предположении, что имеется RGB облако точек, полученное RGB-D камерой с одного или нескольких ракурсов.

Ключевые слова: облако точек, трехмерное пространство, архитектура PointNet, входные данные, пространственные объекты, задачи классификации и сегментации, глобальная функция, визуализация данных

Для цитирования: Л.А. Щенявская, Д.А. Гура, Р.А. Дьяченко. Анализ архитектуры нейронной сети PointNet. Вестник Дагестанского государственного технического университета. Технические науки. 2023; 50(4):158-165. DOI:10.21822/2073-6185-2023-50-4-158-165

Analysis of the PointNet neural network architecture

L.A. Schenyavskaya¹, D.A. Gura^{1,2}, R.A. Dyachenko¹

¹ Kuban State Technological University,

^{1,2} Moskovskaya St., Krasnodar 350072, Russia,

² Kuban State Agrarian University,

^{2,13} Kalinin St., Krasnodar 350044, Russia

Abstract. Objective. Most researchers convert point cloud data into ordinary three-dimensional voxel grids or image collections, which makes the data unnecessarily voluminous and causes problems when processing them. The purpose of the study is to analyze the architecture of the PointNet neural network. **Method.** A unified approach has been applied to solving various

3D recognition problems, ranging from object classification, detail segmentation to semantic scene analysis. **Result.** A comparative analysis of the classification of 2d and 3d objects was carried out, the layers and functions through which classification occurs were studied in detail. A type of neural network is considered that directly uses point clouds, which takes into account the invariance of permutations of points in the input data. The network is determined to provide a unified architecture for applications ranging from object classification, part segmentation, and scene semantics. For semantic segmentation, the input data can be either a single object from the part area segmentation or a small part of the 3D scene. A neural network that is widely used for raster image editing, graphic design, and digital art is a deep point cloud architecture called PointNet. **Conclusion.** A new deep point cloud architecture, PointNet, is introduced. For object classification task, the input point cloud is directly selected from the shape or pre-segmented from the scene point cloud. To obtain a virtual model of the real world, neural network solutions are used, based on the assumption that there is an RGB point cloud obtained by an RGB-D camera from one or several angles.

Keywords: point cloud, three-dimensional space, PaintNet architecture, input data, spatial objects, classification and segmentation tasks, global function, data visualization

For citation: L.A. Schenyavskay, D.A. Gura , R.A. Dyachenko. Analysis of the PointNet neural network architecture. Herald of Daghestan State Technical University. Technical Sciences. 2023; 50(4): 158-165. DOI:10.21822/2073-6185-2023-50-4-158-165

Введение. При появлении приложений, требующих наличие трехмерной среды и взаимодействия с трехмерными объектами, возникла потребность в технологии глубокого обучения, адаптированной к трехмерным данным. Однако, в отличие от изображения, которое имеет доминирующее представление в виде двухмерных пиксельных массивов, трехмерное изображение имеет множество различных представлений. Облако точек является наиболее близким трехмерным представлением к необработанным данным датчиков. Оно также представлено в канонической форме, что означает возможность легкого преобразования трехмерных представлений в облака точек. Большинство существующих функций для работы с облаком точек созданы для решения конкретных задач (табл. 1).

Таблица 1. Характеристика функций облаков точек [1]

Table 1. Characteristics of point cloud functions [1]

Наименование/ Name	Поддерживает текстуру/ Supports texture	Уровень/ Level
PFH (Point Feature Histograms)	НЕТ/NO	Местный/ Local
FPFH (Fast Point Feature Histograms)	НЕТ/NO	Местный/ Local
VFH (Vector Field Histogram)	НЕТ/NO	Глобальный/ Global
CVFH (Clustered Viewpoint Feature Histogram)	НЕТ/NO	Региональный/ Regional
RIFT(radiation-variation insensitive feature transform)	ДА/ YES	Местный/ Local

Постановка задачи. Рассмотрим подробно сеть PointNet, которая обеспечивает простую унифицированную архитектуру для приложений. Она обеспечивает единый подход к решению различных задач трехмерного распознавания (рис. 1), начиная от классификации объектов, сегментации деталей и заканчивая семантическим анализом сцены.

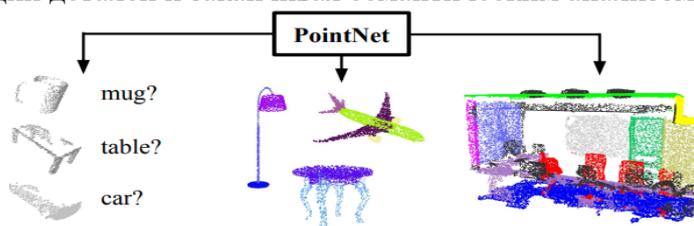


Рис. 1. Задачи, решаемые архитектурой PointNet [2]

Fig. 1. Tasks solved by the PointNet architecture [2]

Необходимо классифицировать 3d объект, но как именно это делать и насколько это отличается от классификации 2d объектов. Классификация в двумерном виде изображения представляется в виде матрицы или тензора.

Методы исследования. Популярным методом является сверточная нейронная сеть (CNN) (рис. 2). Из двумерного изображения можно изучить функции с помощью операций свертки и ввести нелинейность с помощью функций активации, таких как ReLU. Затем объединение можно использовать для уменьшения размерности и сохранения пространственной инвариантности. Слой свертки и слой пула генерируют высокоуровневые функции входного изображения. Затем полносвязные слои используют эти функции для классификации входного изображения. Выходной слой производит вероятности для каждого класса. Класс с наибольшей вероятностью является предсказанным классом для входного изображения [3].

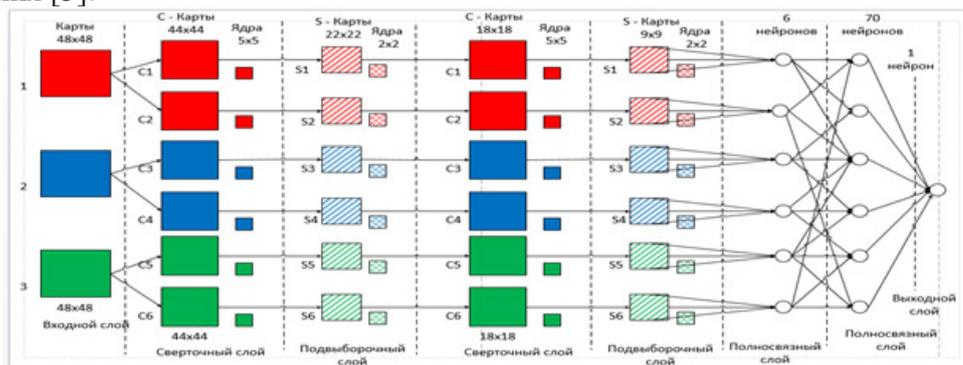


Рис. 2. Интерпретация сверточной нейронной сети [3]

Fig. 2. Interpretation of a convolutional neural network [3]

Классификация двумерных облаков точек представлена довольно просто, но необходимо разобраться как выполняется классификация 3d объектов и как представлены данные на входном уровне. Обратимся к нейронной сети PointNet – популярному методу классификации 3d объектов, на которые в научной литературе ссылаются более 5000 раз [4-8].

Обсуждение результатов. Нейронная сеть PointNet – это глубокая нейронная сеть, предложенная для работы с 3D-объектами. Она была представлена в 2017 году в работе “PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation” авторами Charles R. Qi, Hao Su, Kaichun Mo и Leonidas J. Guibas [2]. Для начала необходимо рассмотреть концепцию, а затем реализацию PyTorch вместе с архитектурой PointNet для лучшего понимания. Начать следует с облака точек, в котором содержится «n» точек. Облако точек – это набор отдельных точек в трехмерном пространстве, где каждая точка представлена своей координатой в плоскости XYZ [9]. Облака точек возникают во многих задачах и позволяют понять, как выглядит окружающий трёхмерный мир. По этой причине размер входных данных равен nx3. Затем входные точки преобразуются входной трансформаторной сетью.

Основная идея этой сети преобразователей состоит в том, чтобы совместить входное облако точек с каноническим пространством. Итак, для чего же выполняется выравнивание? Ответ на поставленный вопрос содержится в определении облака точек. Облако точек – это простой набор точек в трехмерном пространстве и, следовательно, инвариантно к перестановкам его членов [9].

В нейронной сети используется симметричная функция для агрегирования информации с каждой точки, поскольку необходимо, чтобы облако точек было инвариантным к определенным геометрическим преобразованиям, таким как жесткое преобразование, отражение, вращение и перемещение [10].

Для выполнения такого выравнивания к входным координатам точек применяется аффинное преобразование, здесь T-Net используется для прогнозирования. T-Net – трансформаторная сеть, состоящая из базовых модулей независимого от точек [11]. Для облака точек геометрическое преобразование – это просто умножение матриц. Итак, здесь

в основном входные данные перемножаются с входной матрицей, затем в каждую точку встраивается многослойный персептрон (MLP), который независимо захватывает локальные особенности для каждой точки. Это основной блок сети PointNet, который используется для обработки каждой точки в облаке точек. Он состоит из нескольких полносвязных слоев и функции активации ReLU (формула 1, рис. 3) [12]. Он обрабатывает каждую точку входных данных независимо и объединяет их в единый вектор признаков.

$$\text{ReLU}(x) = \max(0, x) \quad (1)$$

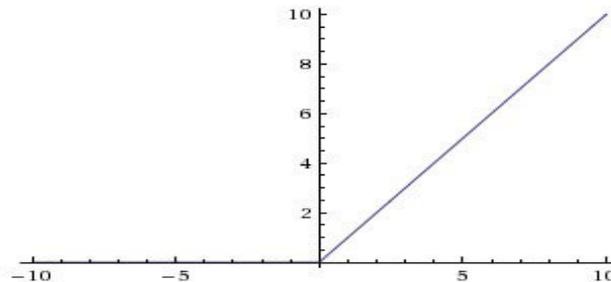


Рис. 3. График функции ReLu [12]

Fig. 3. Graph of the ReLU function [12]

Затем применяется преобразование пространственных объектов. Как и входное преобразование, преобразование объектов используется для выравнивания точек в пространстве встраивания. Однако преобразование пространственных объектов немного отличается. Преобразование пространственных объектов выполняет встраивание в гораздо более высоких измерениях, что значительно усложняет оптимизацию [13]. Именно поэтому к потерям при обучении softmax добавляется член регуляризации, чтобы сделать оптимизацию стабильной (формула 2).

$$L_{reg} = \|I - AA^T\|_F^2, \quad (2)$$

где A – предсказанная матрица выравнивания признаков;

I – матрица идентичности.

Слой softmax: используется для распределения вероятностей между различными классами. Функция представлена в формуле (3), а ее график на рисунке 4.

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{k=1}^K e^{z_k}}, \quad (3)$$

где K указывает на количество классов;

z – входной вектор

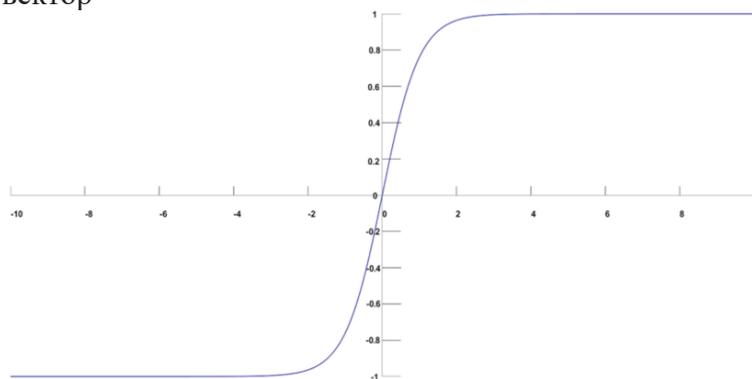


Рис. 4. График функции SoftMax [14]

Fig. 4. Graph of the SoftMax function [14]

Затем каждая точка снова преобразуется в другое пространство вложения, что происходит при помощи многослойного персептрона размеров. После этого используется функция Max Pooling (максимальное объединение) для объединения всех точек в многомерном пространстве встраивания для вывода глобального вектора признаков [15], пример работы этой функции представлен на рис. 5.

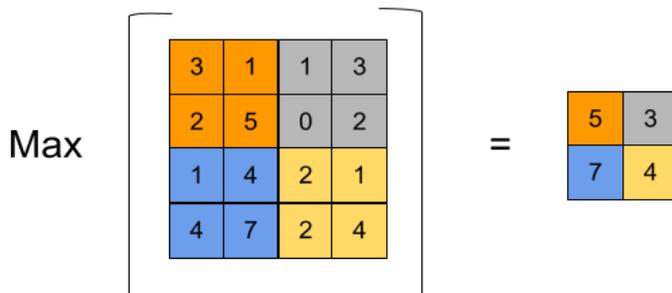


Рис. 5. Функция Max Pooling [16]

Fig. 5. Max Pooling Function [16]

Были проведены эксперименты с другими операциями симметрии, такими как объединение среднего значения и взвешенная сумма на основе внимания, и оказалось, что максимальное объединение (Max Pooling) значительно эффективнее (табл.2).

Таблица 2. Сравнение операций симметрии [2]

Table 2. Comparison of symmetry operations

Наименование/ Name	accuracy
MLP (unsorted input)	24.2
MLP (sorted input)	45.0
LSTM	78.5
Attention sum	83.0
Average pooling	83.8
Max pooling	87.1

Наконец, глобальный вектор обновляется многоуровневым персептроном для вывода оценок классификации для k классов. Класс с наибольшей вероятностью является предсказанным классом для входного облака точек. Архитектура сети PointNet, рассмотренная в статье [2], представлена на рис. 6.

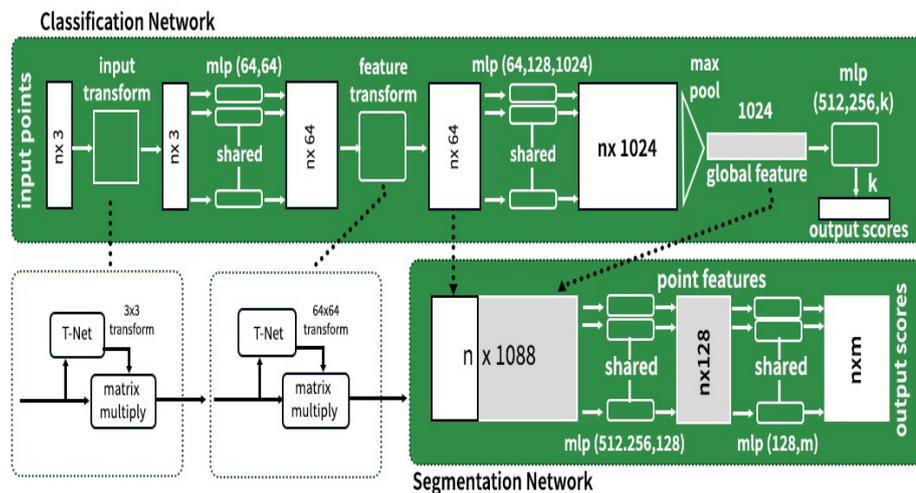


Рис. 6. Архитектура сети PointNet [2]

Fig. 6. Architecture of the Paint net network [2]

Для распространения данной архитектуры на сегментацию, необходимо спрогнозировать оценки класса по каждому баллу. Простой, но эффективный способ сделать это – объединить локальные вложения и глобальные векторы объектов [17].

Для каждой точки можно выбрать локальное вложение с глобальным вектором объектов и использовать его для классификации по точкам, а затем вывести m баллов по каждой точке для проведения сегментации [18].

На рис. 7 показаны некоторые результаты сегментации частей объекта из набора данных параметров shipnet как при частичном, так и при полном вводе.

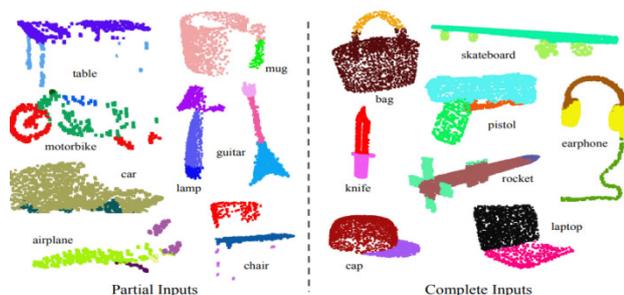


Рис. 7. Результаты сегментации деталей [2]

Fig. 7. Results of segmentation of parts [2]

В количественном отношении нейронная сеть PointNet также превзошла предыдущий уровень техники, используя традиционные функции, а также базовую линию с использованием трехмерной сегментации пути объекта CNN [2] (табл.3).

Таблица 3. Результаты классификации по ModelNet 40 [2]

Table 3. Classification results by ModelNet 40 [2]

Наименование/ Name	input	#views	accuracy avg. class	accuracy overall
SPH	mesh	-	68.2	-
3DShapeNets	volume	1	77.3	84.7
VoxNet	volume	12	83.0	85.9
Subvolume	volume	20	86.0	89.2
LFD	image	10	75.5	-
MVCNN	image	80	90.1	-
baseline	point	-	72.6	77.4
PointNet	point	1	86.2	89.2

Так же сеть способна четко сегментировать различные семантические области. Помимо высокой производительности в области трехмерного распознавания, сеть также устойчива к повреждению данных, посторонним точкам и точечным возмущениям [19]. Что касается облака точек, то определяется набор точек во входных данных, которые вносят свой вклад в глобальную функцию. Это подмножество точек называют набором критических точек, которые при визуализации составляют основу [20].

Более того, есть возможность найти точки в пространстве, которые не повлияют на глобальный объект. Эти точки не ограничиваются набором входных данных. Любой набор точек, расположенный между набором точек кратера и набором верхних границ, приведет к одному и тому же глобальному векторному объекту.

Это объясняет, почему сеть PointNet настолько устойчива к различным повреждениям данных, таким как пропущенные данные или точечные возмущения. Так же показана аналогичная визуализация для всех категорий выборок. Точка p по-прежнему способна улавливать основные контуры и ключевые структуры, а это означает, что изучение объектов хорошо обобщается на невидимые категории.

Вывод. Разработчики сети предложили новую глубокую архитектуру облака точек под названием PointNet. Для задачи классификации объектов облако входных точек непосредственно выбирается из формы или предварительно сегментируется из облака точек сцены.

Как правило, для получения виртуальной модели реального мира используются нейросетевые решения, основанные на предположении, что имеется RGB облако точек, полученное RGB-D камерой с одного или нескольких ракурсов. В статье были продемонстрированы теоретические и экспериментальные результаты, подтверждающие правильность разработки сети.

Библиографический список:

1. Можаяев А. Н. Сегментация облаков точек с помощью средств библиотеки point cloud library / А. Н. Можаяев // Экстремальная робототехника. – 2018. – Т. 1, № 1. – С. 301-308. – EDN YNCUTJ
2. Zhu X. X., Tuia D., Mou L., Xia G. S., Zhang L., Xu F., Fraundorfer F. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources // IEEE Geoscience and Remote Sensing Magazine. – 2017. – P. 8–36. DOI: 10.1109/MGRS.2017.2762307
3. Ферлитш Э. Шаблоны и практика глубокого обучения / пер. с англ. А. В. Логунова. – М.: ДМК Пресс, 2022. – 538 с. ISBN 978-5-93700-113-9
4. Алиев Р.М., Мирзофат О.Н. «Сравнительный анализ применения методов обработки облаков точек PointNet и PointNet++ для задачи сегментации 3D-объектов» // Труды Института системного программирования РАН. - 2020. - Т. 29. - № 1. - С. 37-54.
5. Мельник С.П., Иванов И.В. «Анализ метода PointNet для задачи сегментации трехмерных объектов» // Информационные технологии и компьютерная инженерия. - 2018. - Т. 16. - № 5. - С. 951-960.
6. Федоров В.И., Поповкин В.В. «Сверточные нейронные сети в задаче классификации облаков точек» // Вестник Российской академии наук. - 2019. - Т. 89. - № 5. - С. 428-436.
7. Курманбаев Б.Б. «Применение метода PointNet для классификации трехмерных объектов» // Вестник КазНТУ. - 2019. - № 4(134). - С. 111-117.
8. Хаустов А.М., Прыгульский М.В. «Анализ предложенной архитектуры PointNet» // Информационные системы и технологии. - 2019. - № 4(98). - С. 49-57.
9. Гура Д.А., Дьяченко Р.А., Хушт Н.И. К вопросу о предобработке данных трехмерного лазерного сканирования // Электронный сетевой политематический журнал «Научные труды КубГТУ». 2021. № 3. С. 39-46. EDN: GKDDTK
10. Гура Д.А., Дьяченко Р.А., Хушт Н.И., Марковский И.Г. К вопросу о методах генерации, классификации и распознавания трехмерных изображений // Электронный сетевой политематический журнал «Научные труды КубГТУ». 2021. № 2. С. 86-97. EDN: KNEICL
11. Гура Д.А., Дьяченко Р.А., Андрущенко А.В. Технология имитации полетного маршрута беспилотного летательного аппарата и воздушного лазерного сканирования // Электронный сетевой политематический журнал «Научные труды КубГТУ». 2022. № 6. С. 126-133. EDN: QPPBDL
12. Кадров И. В. Виды функций активации для обучения свёрточных нейронных сетей / И. В. Кадров, Л. Б. Кижнер // Вопросы устойчивого развития общества. – 2022. – № 6. – С. 1109-1115. – EDN TELYIU.
13. Косолапов П.А., Дьяченко Р.А., Гура Д.А., Хушт Н.И. К вопросу о нормализации данных трехмерного лазерного сканирования // Электронный сетевой политематический журнал «Научные труды КубГТУ». 2021. № 4. С. 56-66. EDN: ILVHIQ
14. Свитов Д. В. Дистилляция моделей для распознавания лиц, обученных с применением функции Софтмакс с отступами / Д. В. Свитов, С. А. Алямкина // Автоматика и телемеханика. – 2022. – № 10. – С. 35-46. – DOI 10.31857/S000523102210004X. – EDN AJXJDG.
15. Krizhevsky I., Sutskever G. E., Hinton. Imagenet classification with deep convolutional neural networks. Communications of the ACM, 60(6):84–90, May 2017. ISSN 0001-0782, 1557-7317. doi: 10.1145/3065386.
16. Малашин Р. О. Глава 12. Современные нейронные сети глубокого обучения для автоматического анализа изображений / Р.О. Малашин, С. В. Пономарев // Нейротехнологии : коллективная монография. – Санкт-Петербург : ВВМ, 2018. – С. 271-335. – EDN DHAIFS.
17. Маенраа Т. The local binary pattern approach to texture analysis – Extensions and Applications. - Oulu University Press, 2003.
18. Zaganidis A., Sun L., Duckett T., Cielniak G. Integrating Deep Semantic Segmentation into 3-D Point Cloud Registration // IEEE Robotics and Automation Letters. – 2018. – Vol. 3, No. 4. – P. 2942–2949. DOI:10.1109/LRA.2018.2848308
19. Орлова С. Р. Трехмерное распознавание: текущее состояние и тенденции / С. Р. Орлова, А. В. Лопота // Автоматика и телемеханика. – 2022. – № 4. – С. 5-26. – DOI 10.31857/S000523102204002X. – EDN AAALWB.
20. Березовский Б. А., Барышников Ю. М., Борзенко В. И., Кемпнер Л. М. Многокритериальная оптимизация: Математические аспекты / Б. А. Березовский, Ю. М. Барышников, В. И. Борзенко, Л. М. Кемпнер. М.: Наука, 1989. - 128 с. - ISBN 5-02-006543-9

References

1. Mozhaev A. N. Segmentation of point clouds by means of the point cloud library. *Extreme robotics*. 2018; 1(1):301-308. – EDN YNCUTJ (In Russ)
2. Zhu X. X., Tuia D., Mou L., Xia G. S., Zhang L., Xu F., Fraundorfer F. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine*. 2017; 8–36. DOI: 10.1109/MGRS.2017.2762307
3. Ferrit S. E. Patterns and practice of deep learning / translated from English by A.V. Logunov. – М.: ДМК Press, 2022; 538. ISBN 978-5-93700-113-9(In Russ)

4. Aliyev R.M., Morozova O.N. "Comparative analysis of the application of point cloud processing methods Paint Net and Paint Net++ for the task of segmentation of 3D objects". *Proceedings of the Institute of System Programming of the Russian Academy of Sciences*. 2020; 29(1):37-54. (In Russ)
5. Melnik S.P., Ivanov I.V. Analysis of the PointNet method for the task of segmentation of three-dimensional objects". *Information technologies and computer engineering*. 2018; 16(5): 951-960. (In Russ)
6. Fedorov V.I., Popovkin V.V. "Convolutional neural networks in the problem of point cloud classification" *Bulletin of the Russian Academy of Sciences*. 2019; 89(5):428-436. (In Russ)
7. Kurmanbaev B.B. "Application of the PointNet method for classification of three-dimensional objects" *Bulletin of KazNTU*. 2019; 4(134): 111-117. (In Russ)
8. Khaustov A.M., Prygulsky M.V. "Analysis of the proposed PointNet architecture". *Information systems and technologies*. 2019; 4(98): 49-57. (In Russ)
9. Gura D.A., Dyachenko R.A., Khusht N.I. On the issue of preprocessing three-dimensional laser scanning data. *Electronic network polythematic journal "Scientific works of KubSTU"*. 2021; 3:39-46. EDN: GKDDTK (In Russ)
10. Gura D.A., Dyachenko R.A., Khusht N.I., Markovsky I.G. On the methods of generation, classification and recognition of three-dimensional images. *Electronic network polythematic journal "Scientific works of KubSTU"*. 2021; 2: 86-97. EDN: KNEICL (In Russ)
11. Gura D.A., Dyachenko R.A., Andryushchenko A.V. Technology of flight route simulation of an unmanned aerial vehicle and aerial laser scanning. *Electronic network polythematic journal "Scientific works of KubSTU"*. 2022; 6: 126-133. EDN: QPPBDL (In Russ)
12. Cadres I. V. Types of activation functions for training convolutional neural networks / I. V. Cadres, L. B. Kizhner. *Issues of sustainable development of society*. 2022; 6: 1109-1115. – EDN TELYIO. (In Russ)
13. Kosolapov P.A., Dyachenko R.A., Gura D.A., Khusht N.I. On the normalization of three-dimensional laser scanning data. *Electronic network polythematic journal "Scientific works of KubSTU"*. 2021; 4: 56-66. EDN: ILVHIQ (In Russ)
14. Svitov D. V. Distillation of models for face recognition trained using the Softmax function with indents / D. V. Svitov, S. A. Alyamkin. *Automation and telemechanics*. 2022; 10:35-46. – DOI 10.31857/S000523102210004X. – EDN AJXJDG. (In Russ)
15. Krizhevsky I., Sutskever G. E. Hinton. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6):84–90, May 2017. ISSN 0001-0782, 1557-7317. doi: 10.1145/3065386.
16. Malashin R. O. Chapter 12. Modern neural networks of deep learning for automatic image analysis / R. O. Malashin, S. V. Ponomarev. *Neurotechnologies : a collective monograph*. St. Petersburg : VVM, 2018; 271-335. – EDN DHAIFS. (In Russ)
17. Maenpaa T. The local binary pattern approach to texture analysis – Extensions and Applications. Oulu University Press, 2003.
18. Zaganidis A., Sun L., Duckett T., Cielniak G. Integrating Deep Semantic Segmentation into 3-D Point Cloud Registration. *IEEE Robotics and Automation Letters*. 2018;3(4): 942–2949. DOI:10.1109/LRA.2018.2848308
19. Orlova S. R. Three-dimensional recognition: current state and trends / S. R. Orlova, A.V. Lopota. *Automation and telemechanics*. 2022; 4: 5-26. DOI 10.31857/S000523102204002X. – EDN AAALWB. (In Russ)
20. Berezovsky B. A., Baryshnikov Yu. M., Borzenko V. I., Kempner L. M. Multicriteria optimization: Mathematical aspects / B. A. Berezovsky, Yu. M. Baryshnikov, V. I. Borzenko, L. M. Kempner. M.: Nauka, 1989; 128.- ISBN 5-02-006543-9 (In Russ)

Сведения об авторах:

Щенявская Людмила Андреевна, лаборант кафедры кадастра и геоинженерии; yudmela2311@mail.ru
Гура Дмитрий Андреевич, кандидат технических наук, доцент кафедры кадастра и геоинженерии; gda-kuban@mail.ru

Дьяченко Роман Александрович, доктор технических наук, профессор кафедры информатики и вычислительной техники; emessage@rambler.ru

Information about authors:

Lyudmila A. Shchenyavskaya, Laboratory assistant, Department of Cadastre and Geoengineering; Lyudmela2311@mail.ru

Dmitry A. Gura, Cand. Sci.(Eng.), Assoc.Prof.; Department of Cadastre and Geoengineering; gda-kuban@mail.ru
Roman A. Dyachenko, Dr. Sci.(Eng.), Prof., Department of Informatics and Computer Engineering; emessage@rambler.ru

Конфликт интересов / Conflict of interest.

Авторы заявляют об отсутствии конфликта интересов/The authors declare no conflict of interest.

Поступила в редакцию/ Received 05.09.2023.

Одобрена после рецензирования / Revised 30.09.2023.

Принята в печать /Accepted for publication 30.09.2023.