

Сверточная нейронная сеть в задаче классификации облаков точек в трёхмерном пространстве

А.Ю. Маковецкий¹, В.И. Кобер¹, Д.Е. Жернов¹, А.В. Воронин¹

¹Челябинский государственный университет, Братьев Кашириных 129, Челябинск, Россия, 454001

Аннотация

Результатом работы большинства устройств сбора 3D данных являются облака точек в трёхмерном пространстве. Применение сверточных нейронных сетей (CNN) в задачах анализа изображений показывает преимущество нейросетевых алгоритмов перед алгоритмами классического типа для некоторых типов задач. Успех нейронных сетей при анализе традиционных 2D изображений привел к началу адаптации нейронных сетей к применению в задачах обработки трехмерных данных. Облака точек по своей природе не содержат в явном виде информацию о геометрии объекта, поэтому методы, которые восстанавливают геометрические характеристики облака точек, могут расширить возможности нейронной сети. В статье рассматривается нейронная сеть для решения задач обработки облаков точек в трёхмерном пространстве. Сверточная нейронная сеть используется для решения задачи классификации объектов, заданных облаками точек. Предлагаемый подход не зависит от выбора нумерации точек в облаке. Для компьютерного моделирования использовалась база данных ModelNet40.

Ключевые слова

Облако точек, изменение размерности данных, сверточная нейронная сеть, полносвязная нейронная сеть, классификация

1. Введение

Облака точек в трёхмерном пространстве являются простым способом задания объектов, который часто применяется в технике для 3D зондирования, в частности, в 3D сканерах и системах стереорекострукции. Некоторые из многих недавних систем обработки и анализа облаков точек в трёхмерном пространстве включают навигацию [1], беспилотные автомобили [2-4], робототехнику [5], моделирование объектов [6,7]. Эти современные приложения требуют высокоуровневой обработки облаков точек. Вместо того, чтобы определять геометрические элементы, такие как углы и края, новые алгоритмы используют семантическое соответствие. Эти методы требуют подходов, основанных на обучении, работа которых основана на статистическом анализе помеченных наборов данных.

Задача адаптации методов глубокого обучения к обработке облаков точек в трёхмерном пространстве остается сложной проблемой. Стандартная модель глубокой нейронной сети требует входных данных с регулярной структурой, таких как векторы и матрицы. 3D облака точек принципиально нерегулярны: позиции точек непрерывно распределены в пространстве, и любая перестановка их порядка не меняет пространственного распределения. Одним из известных подходов к обработке облаков точек с использованием глубокого обучения является преобразование облака точек в 3D сетку [8,9]. Этот подход часто приводит к артефактам квантования и чрезмерному использованию памяти. Современные глубокие нейронные сети созданы специально для обработки облаков точек напрямую, без перехода к промежуточному регулярному представлению. Этот подход был впервые реализован в нейронной сети PointNet [10]. В сети DGCNN [11] реализована инвариантность относительно выбора нумерации точек на основе использования динамически определяемого отношения соседства точек в евклидовом пространстве высокой размерности. В данной работе рассматривается архитектура нейронной сети, близкая к архитектуре DGCNN, с использованием статически определенного

отношения соседства точек. Предлагаемая сеть применяется для решения задачи классификации 3D объектов, заданных облаками точек.

2. Используемая база данных

В качестве базы данных, содержащей облака точек, использовалась ModelNet40. Были выбраны четыре класса объектов, см. Рисунок 1. Всего в тренировочное множество вошло 1690 облаков точек. Каждое облако состоит из 1024 точек, облака централизованы и нормализованы.




Рисунок 1: Четыре класса объектов, задаваемых облаками точек: самолеты, ванны, кровати, скамейки

Нейронная сеть, с архитектурой, близкой к DGCNN, использовалась для решения задачи классификации объектов четырех типов. Получена вероятность правильного распознавания класса объекта 0,878. Точность работы предложенной сети близка к точности известной нейронной сети для работы с облаками точек в трехмерном пространстве PointNet.

3. Благодарности

Работа поддержана грантом РФФИ № 20-47-740007.

4. Литература

- [1] Zhu, Y. Target-driven Visual Navigation in Indoor Scenes using Deep Reinforcement learning / Y. Zhu, R. Mottaghi, E. Kolve, J. Lim, A. Gupta, L. Fei-Fei, A. Farhadi // Proc. ICRA. – 2017.
- [2] Liang, M. Deep Continuous Fusion for Multi-Sensor 3D Object Detection / M. Liang, B. Yang, S. Wang, R. Urtasun // The European Conference on Computer Vision (ECCV). – 2018.
- [3] Litany, Q. Deformable Shape Completion with Graph Convolutional Autoencoders / Q. Litany, A. Bronstein, M. Bronstein, A. Makadia // ArXiv: 1712.00268. – 2017.
- [4] Wang, X. Non-local Neural Networks / X. Wang, R. Girshick, A. Gupta, K. He // CVPR. – 2018.
- [5] Rusu, R. Towards 3D Point Cloud Based Object Maps for Household Environments / R. Rusu, Z. Marton, N. Blodow, M. Dolha, M. Beetz // Robotics and Autonomous Systems Journal. – 2008. – Vol. 56(11). – P. 927-941.
- [6] Golovinskiy, A. Shape-based Recognition of 3D Point Clouds in Urban Environments / A. Golovinskiy, V. Kim, T. Funkhouser // Proc. ICCV. – 2009.
- [7] Guerrero, P. PCPNet: Learning Local Shape Properties from Raw Point Clouds / P. Guerrero, Y. Kleiman, M. Ovsjanikov, N. Mitra // Computer Graphics Forum. – 2018. – Vol. 37(2) – P. 75-85.
- [8] Maturana, D. Voxnet: A 3D Convolutional Neural Network for Real-time Object Recognition / D. Maturana, S. Scherer // Proc. IROS. – 2015.
- [9] Wu, Z. 3D Shapenets: A Deep Representation for Volumetric Shapes / Z. Wu, S. Song, A. Khosla, F. Yu, L. Zhang, X. Tang, J. Xiao // Proc. CVPR. – 2015.
- [10] Qi, C. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation / C. Qi, H. Su, K. Mo, L. Guibas // Proc. CVPR. – 2017.
- [11] Wang, Y. Dynamic graph cnn for learning on point clouds / Y. Wang, S. Sun, S. Ziwei, M. Liu, M. Bronstein, J. Solomon // ArXiv preprint: 1801.07829. – 2018.