

УДК 004.85

КОНЦЕПТУАЛЬНА МОДЕЛЬ ДОПОВНЕННЯ ТОЧКОВИХ ХМАР НА ОСНОВІ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ

Чухран І.Д., Чала Л.Е.

e-mail: ivan.chukhran@nure.ua, larysa.chala@nure.ua

Харківський національний університет радіоелектроніки, каф. ШІ
м. Харків, Україна

A conceptual model for completing point clouds using graph neural networks has been developed, which allows to efficiently encode incomplete point clouds as graphs and predict missing points. The proposed approach allows for high-quality reconstruction of incomplete 3D data, which is extremely important for many applications such as 3D reconstruction, robot navigation, etc. Research methods are analysis and synthesis of scientific literature, systematic approach, machine learning methods, in particular graph neural networks. Further research may involve testing different neural network architectures, tuning hyperparameters, applying alternative loss functions, and using more powerful computing resources to train deep models.

Використання представлення тривимірних об'єктів або середовищ у вигляді набору неструктурованих точок у просторі, набуває все більшого поширення в різних сферах, включаючи автономну навігацію, робототехніку, віртуальну/доповнену реальність та 3D-реконструкцію. Здатність точно фіксувати і обробляти дані 3D хмари точок має вирішальне значення для додатків, які вимагають всебічного розуміння навколишнього середовища, таких як об'їзд перешкод, планування шляху і моделювання сцен.

Однак, через оклюзії, обмеження датчиків або недосконалість процесів збору даних, хмари точок часто містять пропущені області або неповне представлення захоплених об'єктів або сцен. Ця неповнота може створювати значні проблеми для подальших задач, які покладаються на точну і повну 3D інформацію, що потенційно може призвести до помилок або неоптимальної продуктивності у критично важливих додатках.

Основною задачею даної роботи було обрано вирішення проблеми заповнення неповних тривимірних точкових хмар задля забезпечення надійної і достовірної обробки вищенаведених даних. Існує два напрямки в методах вирішення: традиційні методи та методи, в основі яких лежить глибинне навчання нейронних мереж.

До перших переважно відносять підходи, в яких використовується поняття симетрія та дисперсія форми об'єкту, тому, зазвичай, вони використовуються для заповнення локальних пропусків на основі сусідніх регіонів шляхом інтерполяції поверхні [1]. Підходи на основі вирівнювання [2] використовують переваги великомасштабної бази даних вже відомих об'єктів і форм для пошуку найбільш релевантних доповнень.


Методи з використанням глибинного навчання можна поділити підтипи в залежності від обраного підходу. Деякі з робіт [3] використовували мережі типу кодування-декодування або автокодувальні мережі з різними представленнями та обробкою точкових хмар (починаючи від одновимірної згортки по хмарах до ієрархічного фільтрування ознак). Інші пропонують вирішення за допомогою генеративних змагальних мереж або використовують гіпермережі, основною особливістю яких є можливість генерувати вагові коефіцієнти для іншої мережі, яка буде вирішувати задачу реконструкції [4].

У даній роботі було описано підхід, в рамках якого було запропоновано й навчено графову нейронну мережу. Такий вибір зумовлений можливістю опрацьовувати неструктуровані або напівструктуровані дані на різних рівнях – на рівні вузлів, ребер та/або цілих графів.

Дана мережа є автокодувальною [5], яка використовує графову мережу в якості механізму кодування точкових хмар. Кодувальна мережа побудована на основі операції графової згортки EdgeConv.

Більшість точкових хмар представлені без надання інформації про сусідні точки, тому для того, щоб можна було використовувати графові мережі, також необхідно трансформувати вхідні дані до вигляду графу, що було зроблено за допомогою використання алгоритму К-найближчих сусідів.

Для навчання мережі було використано набір даних Shapenet, який було обмежено до одного класу “Літак” через технічні обмеження. Під час тренування було також використано підхід агрегації отриманих значень функцій втрат (розбіжність Дженсена-Шеннона для точкових хмар), що допомогло більш критично ставитись до помилок в проміжних етапах генерації доповнення. Загальний час тренування склав 34 години. Графік функції втрат під час тренування наведено на рисунку 1.



Рисунк 1 – Графік функції втрат під час тренування

Результати навчання продемонстрували значення функції втрат 29.01 на навчальній вибірці та 31.11 на валідаційній вибірці. За допомогою наведених графіків на рисунку 1 можна встановити, що, починаючи з 200

епохи, нейронна мережа виходить на плато. Це означає, що модель вже досягла своїх можливостей навчання на даному наборі даних.

На рисунку 2 наведено приклад візуалізації даних для відновленої та очікуваної моделей.




Рисунок 2 – Приклад візуалізації даних для відновленої та очікуваної моделей

Подальші дослідження можуть стосуватися випробування різних архітектур нейронних мереж, налаштування гіперпараметрів, застосування альтернативних функцій втрат та використання більш потужних обчислювальних ресурсів для навчання глибоких моделей. Додаткові експерименти з різними класами об'єктів або більш складними наборами даних також можуть допомогти оцінити загальну здатність моделей та виявити їхні сильні та слабкі сторони.

Список використаних джерел:

1. State of the Art in Surface Reconstruction from Point Clouds / M. Berger et al. DSpace Repository. URL: <https://diglib.eg.org/items/d9bfd0be9d3e-4ced-8d25-ef522dc454f3> (дата звернення: 03.05.2025).
2. Structure recovery by part assembly / C.-H. Shen et al. ACM Transactions on Graphics. 2012. Vol. 31, no. 6. P. 1-11. URL: <https://doi.org/10.1145/2366145.2366199> (дата звернення: 03.05.2025).
3. PF-Net: Point Fractal Network for 3D Point Cloud Completion / Z. Huang et al. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 13–19 June 2020. 2020. URL: <https://doi.org/10.1109/cvpr42600.2020.00768> (дата звернення: 03.05.2025).
4. HyperPocket: Generative Point Cloud Completion / P. Spurek et al. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Kyoto, Japan, 23-27 October 2022. 2022. URL: <https://doi.org/10.1109/iros47612.2022.9981829> (дата звернення: 03.05.2025).
5. Udovenko S., Chala L., Inzhyants A. Application of evolutionary optimization for processing noisy images. Proceedings of 10th international scientific and practical conference «Analysis of modern ways of development of science and scientific discussions», Bilbao, 29 November – 2 December 2022.