

DOI: 10.34185/1991-7848.itmm.2026.01.008

**КЛАСИФІКАЦІЯ ПРОСТОРОВИХ СТАНІВ ОБ'ЄКТІВ НА ОСНОВІ КАРТ
ВИСОТ ІЗ ВИКОРИСТАННЯМ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ
СИСТЕМ СЕНСОРНОГО СОРТУВАННЯ РУД**

Кондрашов Д.А.¹ [ORCID], Музика І.О.² [ORCID],

Купін А.І.³ [ORCID], Балик Д.К.⁴ [ORCID]

¹ Криворізький національний університет, м. Кривий Ріг, аспірант, Україна

² Криворізький національний університет, м. Кривий Ріг, к.т.н., доцент, Україна

³ Криворізький національний університет, м.Кривий Ріг, д.т.н.,професор, Україна

⁴ТОВ "НВП Гамаюн", м.Кривий Ріг, інженер-програміст вбудованих систем, Україна

Анотація. У роботі розглядається задача автоматичної класифікації просторових станів об'єктів (одиначний, об'єднаний, накладений) у системах прецизійного сенсорного сортування рудної сировини. Запропоновано підхід на основі перетворення тривимірних хмар точок, отриманих від лазерного сканера, у двовимірні карти висот з подальшою класифікацією за допомогою згорткових нейронних мереж (CNN). Досліджено вплив розмірності сітки (32×32, 64×64, 128×128) та архітектури моделі на якість класифікації. Проведено порівняльний аналіз п'яти архітектур: MLP, базова CNN, CNN+Dropout, CNN+L1 та поглиблена CNN. Встановлено, що поглиблена CNN на реальних даних забезпечує точність до 92% на валідаційній вибірці при розмірності 64×64.

Ключові слова: сенсорне сортування руд, карта висот, лазерне сканування, згорткова нейронна мережа, машинне навчання, класифікація, хмара точок, перенавчання, аугментація.

Вступ. Ефективність гірничо-збагачувальних комбінатів значною мірою залежить від якості первинного сортування рудної сировини. Сучасні системи сенсорного сортування використовують різноманітні типи сенсорів – від оптичних камер до 3D лазерних сканерів. Однак традиційні детерміновані алгоритми демонструють обмежену ефективність в умовах накладання та зближення шматків руди на конвеєрі: частка помилкових спрацювань може досягати 15–25%. Лазерне сканування дозволяє отримувати геометричну інформацію, інваріантну до умов освітлення та оптичних властивостей поверхні, однак автоматична інтерпретація таких даних залишається складною

задачею. Це обумовлює доцільність застосування методів машинного навчання для аналізу карт висот.

Основний матеріал

Задача та метод формування карт висот. Розглядається задача трикласової класифікації: одиночний об'єкт (Single), візуально об'єднані об'єкти (United) та накладені об'єкти (Overlapped). Карта висот формується із хмари точок $\{(x_k, y_k, z_k)\}$ за формулою:

$$H(i, j) = \max \{ z_k \mid (x_k, y_k) \in \text{cell}(i, j) \} \quad (1)$$

де $\text{cell}(i, j)$ – область простору X-Y для клітинки (i, j) регулярної сітки. Клітинки без точок заповнюються нулем; матриця нормалізується до діапазону $[0, 1]$. Така проєкція зберігає геометричну інформацію і є інваріантною до умов освітлення.

Датасет та аугментація. На першому етапі використовувалися синтетичні дані (по 500 зразків на клас), що підтвердило коректність підходу (точність >99%). Реальний датасет сформовано з CSV-файлів лазерного сканування фізичних зразків рудної сировини для трьох розмірностей сіток (32×32 , 64×64 , 128×128). Аугментація здійснювалася ротацією на 90° , 180° , 270° , що збільшило обсяг вибірки вчетверо та забезпечило інваріантність моделі до орієнтації об'єктів на конвеєрі. Реальні дані характеризуються наявністю дефектів: пропуски значень, нерівномірність поверхні, артефакти сканування.

Вплив розмірності. Порівняння трьох розмірностей сітки на реальних даних показало (таблиця 1): розмірність 32×32 забезпечує стабільне навчання з мінімальним перенавчанням (train/val: 0.94/0.91); розмірність 64×64 дає найкращий баланс якості та узагальнення (0.98/0.90); розмірність 128×128 призводить до явного перенавчання (1.0/0.85). Таким чином, оптимальною є розмірність 64×64 .

Таблиця 1

Точність класифікації залежно від розмірності карти висот

Розмірність	Train accuracy	Val accuracy	Перенавчання
32×32	0.94	0.91	Мінімальне
64×64	0.98	0.90	Помірне
128×128	1.00	0.85	Значне

Архітектури нейронних мереж. Досліджено п'ять архітектур. MLP (базова лінія) не враховує просторову структуру даних. Базова CNN містить два згорткові блоки Conv2D + MaxPooling. CNN+Dropout та CNN+L1 додають механізми регуляризації для зменшення перенавчання. Поглиблена CNN (Deep CNN) – основна запропонована архітектура: Conv2D(16) → Pool → Conv2D(32) → Pool → Conv2D(64) → Pool → Dense(64) → Dense(3, softmax), активація ReLU, оптимізатор Adam (lr=0.001), функція втрат – categorical cross-entropy. Поступове збільшення фільтрів 16→32→64 дозволяє виявляти ознаки від низькорівневих (границі, градієнти) до складних просторових структур.

Результати порівняльного аналізу. Навчання на реальних даних 64×64 (розбиття 70/30, 50 епох, Early Stopping). Поглиблена CNN досягає 92% точності на валідаційній вибірці, що на 29 в.п. перевищує MLP (63%) та на 9 в.п. – базову CNN (83%). CNN+Dropout показує найменше перенавчання (різниця train/val лише 2%), але абсолютна точність дещо нижча (89%). Аналіз помилок виявив, що класи United та Overlapped найчастіше плутаються між собою в граничних випадках, тоді як клас Single розпізнається надійно (>95%) у всіх архітектурах.

Висновки

1. Підхід на основі перетворення хмар точок у карти висот із подальшою класифікацією за допомогою CNN є ефективним методом розпізнавання просторових станів об'єктів у системах сенсорного сортування руд.

2. Поглиблена CNN (3 блоки Conv2D+Pool, фільтри 16→32→64) забезпечує найвищу точність – 92% на реальних даних (64×64), перевищуючи базовий MLP на 29 в.п.

3. Оптимальною розмірністю карти висот є 64×64: забезпечує найкращий баланс між деталізацією просторової інформації та узагальнювальними властивостями моделі.

4. Ротаційна аугментація (0°/90°/180°/270°) ефективно збільшує обсяг датасету та забезпечує інваріантність моделі до орієнтації об'єктів. Напрями подальших досліджень: архітектури ResNet/EfficientNet, крос-датасетна валідація, оптимізація для роботи в режимі реального часу.

ЖИТЕПАТҮПА / REFERENCE

1. Chalapathy R., Chawla S. Deep Learning for Anomaly Detection: A Survey // ACM Computing Surveys. – 2019. – Vol. 51, No. 5. – DOI: 10.1145/3299869.
2. Gholami A. et al. A Survey of Quantization Methods for Efficient Neural Network Inference // Low-Power Computer Vision. – 2021. – DOI: 10.1201/9781003162810-13.
3. Parisi G. I. et al. Continual Lifelong Learning with Neural Networks: A Review // Neural Networks. – 2019. – Vol. 113. – DOI: 10.1016/j.neunet.2019.01.012.
4. Peukert S. et al. A Review of Sensor-Based Sorting in Mineral Processing // Minerals. – 2022. – Vol. 12, No. 11. – DOI: 10.3390/min12111364.
5. Qi C. R. et al. PointNet++: Deep Hierarchical Feature Learning on Point Sets // NeurIPS. – 2017. – P. 5099–5108.
6. Rai S. et al. Application of Machine Learning Algorithms for Mineral Classification // Minerals Engineering. – 2021. – Vol. 170. – DOI: 10.1016/j.mineng.2021.107054.
7. Robben C., Wotruba H. Sensor-Based Ore Sorting Technology in Mining // Minerals. – 2019. – Vol. 9, No. 9. – DOI: 10.3390/min9090523.
8. Wang M., Deng W. Deep Visual Domain Adaptation: A Survey // Neurocomputing. – 2018. – Vol. 312. – DOI: 10.1016/j.neucom.2018.05.083.

CLASSIFICATION OF SPATIAL OBJECT STATES BASED ON HEIGHT MAPS USING CONVOLUTIONAL NEURAL NETWORKS FOR ORE SENSOR SORTING SYSTEMS

Dmytro Kondrashov, Andrew Kupin, Ivan Muzyka, Dmytro Balyk

Abstract. *This paper addresses the problem of automatic classification of spatial object states – single, united (close but non-overlapping), and overlapped – in precision sensor-based ore sorting systems. A method for transforming 3D point clouds obtained from a laser scanner into 2D height maps is proposed, followed by classification using convolutional neural networks (CNN). The influence of grid resolution (32×32, 64×64, 128×128) and model architecture on classification quality is investigated. A comparative analysis of five architectures is conducted: MLP, basic CNN, CNN+Dropout, CNN+L1, and Deep CNN. Results demonstrate that the Deep CNN achieves up to 92% validation accuracy on real data at 64×64 resolution, outperforming the MLP baseline by 29 percentage points.*

Keywords: *sensor ore sorting, height map, laser scanning, convolutional neural network, machine learning, classification, point cloud, overfitting, data augmentation.*