

Д.А. Кондрашов, І.О. Музика, А.І. Купін, Д.К. Балик

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

*Анотація.* У статті розглядається задача автоматичної класифікації просторових станів об'єктів у системах прецизійного сенсорного сортування рудної сировини. Актуальність дослідження обумовлена обмеженою ефективністю традиційних алгоритмів сегментації в умовах накладання та зближення шматків руди на конвеєрі. Метою роботи є розробка та дослідження підходу до класифікації трьох просторових станів об'єктів (одиначний, об'єднаний, накладений) на основі карт висот, отриманих за допомогою лазерного сканування. Як метод дослідження використовуються згорткові нейронні мережі (CNN). Проведено порівняльний аналіз архітектур MLP, базової CNN, CNN із регуляризацією та поглибленої CNN. Досліджено вплив розмірності карти висот ( $32 \times 32$ ,  $64 \times 64$ ,  $128 \times 128$ ) на якість класифікації. Встановлено, що поглиблена CNN демонструє найкращу точність на реальних даних – до 90% на валідаційній вибірці при розмірності  $64 \times 64$ . Виявлено ефект перенавчання при збільшенні розмірності вхідних даних. Отримані результати підтверджують перспективність застосування CNN для аналізу карт висот у задачах інтелектуального керування процесом сортування.

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

**Постановка проблеми.** Ефективність сучасних гірничо-збагачувальних комбінатів значною мірою визначається якістю первинного сортування рудної сировини. Процес прецизійного сортування руд передбачає автоматичне розпізнавання та відбраковування некондиційних шматків руди на основі аналізу їх фізико-хімічних властивостей та геометричних характеристик. Сучасні системи сенсорного сортування використовують різноманітні типи сенсорів: оптичні камери, NIR/hyperspectral сканери, рентгенівські детектори (XRT), електромагнітні сенсори та 3D лазерні сканери [7].

Однією з ключових проблем при застосуванні систем сенсорного сортування є складність аналізу просторового стану об'єктів у рудному потоці. Зокрема, на конвеєрній стрічці шматки руди можуть знаходитися у трьох принципово різних конфігураціях: у вигляді окремих об'єктів, у вигляді об'єктів, які візуально зближені але фізич-

но не торкаються один одного, а також у вигляді об'єктів, що фізично перекривають один одного.

Традиційні детерміновані алгоритми комп'ютерного зору з фіксованими пороговими значеннями для класифікації та сегментації демонструють обмежену здатність до адаптації та потребують експертного налаштування під конкретні умови експлуатації. За даними промислових підприємств, частка помилкових спрацювань при використанні класичних методів може досягати 15–25%, що призводить до втрат корисних компонентів або забруднення кондиційного продукту [7]. Це обумовлює необхідність розробки інтелектуальних методів аналізу просторових даних, здатних автоматично виявляти складні закономірності та адаптуватися до мінливих умов роботи.

Лазерне сканування дозволяє отримувати просторову інформацію про поверхню об'єктів у вигляді тривимірних хмар точок або карт висот. На відміну від 2D зображень, такі дані містять геометричну інформацію, яка є інваріантною до умов освітлення та оптичних властивостей поверхні. Проте суттєвою проблемою залишається складність автоматичної інтерпретації таких даних, особливо у випадках, коли об'єкти розташовані близько один до одного або накладаються. У таких ситуаціях традиційні алгоритми обробки зображень та сегментації демонструють нестабільні результати, що обумовлює доцільність застосування методів машинного навчання.

**Аналіз останніх досліджень і публікацій.** Питання застосування методів машинного навчання для класифікації рудної сировини активно досліджується останніми роками. У роботі Robben C. та Wotruba H. [7] представлено всебічний огляд технологій сенсорного сортування в мінеральній промисловості. Автори аналізують різноманітні типи сенсорів та практичні кейси впровадження систем сенсорного сортування, що демонструють підвищення ефективності збагачення на 12–18%. Однак відзначається, що традиційні підходи з фіксованими алгоритмами класифікації мають обмежену ефективність при зміні характеристик рудного потоку, що підкреслює необхідність розробки адаптивних інтелектуальних систем.

У роботі Peukert S. та співавторів [4] проведено комплексний аналіз використання електромагнітного спектру в процесах сенсорного сортування. Автори досліджують можливості поєднання 3D геометричної інформації від лазерних сканерів зі спектральними даними від hyperspectral камер. Встановлено, що мультисенсорний підхід дозволяє підвищити точність класифікації на 8–12% порівняно з використанням одного типу сенсорів. Особливо ефективним виявилось поєднання геометричних характеристик (форма, розмір, текстура поверхні) з інформацією про мінералогічний склад, отриманою зі спектральних даних.

Застосування CNN для аналізу 2D зображень шматків руди розглянуто у роботі Rai S. та співавторів [6]. Експериментальні дослідження показали точність класифікації 89–94% для трьох типів руд. Однак дослідження обмежене аналізом лише 2D зображень без урахування просторової геометрії, що знижує ефективність розпізнавання при накладанні проєкцій декількох шматків.

Перспективним напрямком є застосування 3D нейронних мереж для аналізу хмар точок. У роботі Qi C. R. та співавторів [5] запропоновано архітектуру PointNet++ для

класифікації 3D об'єктів у хмарах точок. Ця архітектура дозволяє ефективно обробляти нерегулярні та неоднорідні 3D дані, типові для лазерного сканування. Точність класифікації на тестових датасетах перевищила 92%. Однак дослідження проводилося на синтетичних даних та не враховувало специфіки промислового застосування.

Методи виявлення аномалій та нестандартних ситуацій у промислових процесах досліджено у роботі Chalapathy R. та Chawla S. [1]. Автори пропонують використання автоенкодерів та методів One-Class SVM для виявлення відхилень від нормального режиму роботи. Точність виявлення аномалій склала 85–91% при рівні помилкових спрацювань 3–7%.

Питання оптимізації нейронних мереж для роботи в режимі реального часу розглянуто у роботі Gholami A. та співавторів [2]. Застосування методів квантизації та grouping дозволяє прискорити інференс у 3–5 разів зі зниженням точності класифікації лише на 1–2%, що є важливим для промислових систем, де час обробки одного об'єкта не повинен перевищувати 50–100 мс.

Методи transfer learning та domain adaptation для адаптації моделей до змін у вхідних даних досліджено у роботах Wang M. та Deng W. [8], а також Parisi G. I. та співавторів [3]. Ці підходи особливо актуальні для систем сенсорного сортування, де характеристики рудної сировини можуть змінюватися залежно від родовища та умов видобутку.

Таким чином, аналіз літератури виявляє значний науковий інтерес до застосування методів машинного навчання у системах сенсорного сортування руд. Однак більшість досліджень зосереджена на класифікації за 2D зображеннями або спектральними даними, тоді як потенціал аналізу карт висот від 3D лазерного сканування для задачі розпізнавання просторових конфігурацій об'єктів залишається недостатньо вивченим. Окремою невирішеною проблемою є побудова ефективних класифікаторів, здатних розрізняти одиночні, об'єднані та накладені об'єкти за даними лазерного сканування.

**Мета дослідження.** Метою даної роботи є розробка та дослідження підходу до автоматичної класифікації просторових станів об'єктів (одиночний, об'єднаний, накладений) на основі карт висот, отриманих від лазерного сканера, із використанням згорткових нейронних мереж, а також порівняльний аналіз різних архітектур нейронних мереж та дослідження впливу розмірності карти висот на якість класифікації.

Для досягнення поставленої мети вирішуються такі задачі: (1) розробка методу формування карт висот на основі тривимірних точкових хмар; (2) генерація та аналіз синтетичного датасету для початкової перевірки підходу; (3) формування реального датасету на основі даних лазерного сканування із застосуванням аугментації; (4) розробка та навчання декількох архітектур нейронних мереж; (5) порівняльний аналіз результатів та виявлення ключових факторів, що впливають на якість класифікації.

## **Викладення основного матеріалу дослідження**

### **1. Постановка задачі та формування карт висот**

У роботі розглядається задача багатокласової класифікації стану об'єктів на основі їх представлення у вигляді дискретизованих карт висот. Вхідними даними є мат-

риці розміром  $N \times N$ , що відображають висоту поверхні об'єктів у кожній точці регулярної сітки. Кожному об'єкту відповідає один із трьох класів: одиночний об'єкт (Single) – окремий шматок руди на конвеєрі; візуально об'єднані об'єкти (United) – два або більше шматки, розташовані близько один до одного, але без фізичного перекриття; накладені об'єкти (Overlapped) – шматки, що фізично перекривають один одного по вертикальній проекції.

Карта висот формується на основі тривимірних точкових хмар, отриманих від лазерного сканера. Процедура формування включає такі кроки: (1) дискретизація простору  $X$ - $Y$  з кроком, що визначає розмірність сітки  $N \times N$ ; (2) для кожної клітинки  $(i, j)$  сітки визначається максимальне значення координати  $Z$  серед усіх точок, що потрапляють до відповідної комірки; (3) клітинки без точок заповнюються нульовим значенням; (4) отримана матриця нормалізується до діапазону  $[0, 1]$ .

Формально, якщо  $P = \{(x_k, y_k, z_k)\}$  – множина точок хмари, а  $G$  – регулярна сітка з розміром клітинки  $\Delta$ , то карта висот  $H$  визначається як:

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

де  $\text{cell}(i, j)$  – область простору  $X$ - $Y$ , що відповідає клітинці  $(i, j)$  сітки. При відсутності точок у клітинці  $H(i, j) = 0$ .




Рисунок 1 – Приклад синтетично згенерованих карт висот для трьох класів (Single, United, Overlapped)

## 2. Формування та дослідження синтетичних даних

На початковому етапі дослідження було реалізовано генерацію синтетичних даних з метою перевірки працездатності підходу та відлагодження процедури формування карт висот. Кожен об'єкт моделювався як набір тривимірних точок із координатами  $(X, Y, Z)$ , де координати  $X$  та  $Y$  задавали положення в площині, а  $Z$  – висоту. Форма об'єктів апроксимувалася еліпсоїдом із випадковими параметрами, що дозволяло моделювати природну варіативність форми шматків руди.

Для кожного класу було розроблено окрему процедуру генерації: для класу Single генерувався один об'єкт, розміщений у центральній частині поля спостереження; для класу United генерувалися два об'єкти, розташовані поряд з відстанню, меншою за їх характерний розмір, але без перетину; для класу Overlapped генерувалися два або більше об'єкти з перетинними горизонтальними проекціями. У кожному випадку генерувалося по 500 зразків із випадковими параметрами, що забезпечувало достатнє різноманіття навчальних прикладів.

Результати навчання нейронної мережі на синтетичних даних показали майже ідеальну точність класифікації – понад 99% як на тренувальній, так і на валідаційній вибірках. Це свідчило про надмірну спрощеність задачі: синтетичні об'єкти мали чіткі та ідеальні геометричні форми, що не відповідає реальним умовам. Крім того, розподіл класів у синтетичних даних виявився надто рівномірним порівняно з реальними даними. Дані результати підтвердили правильність методологічного підходу, але показали необхідність переходу до більш реалістичних даних для отримання практично значущих результатів.

### 3. Реальний датасет та аугментація даних

Після дослідження синтетичних даних було здійснено перехід до роботи з реальними картами висот, отриманими в результаті лазерного сканування фізичних зразків рудної сировини. Дані були представлені у вигляді CSV-файлів, кожен із яких містить матрицю значень висоти для одного зразка. Датасет було організовано у ієрархічну структуру за класами та розмірностями сіток.

Для кожного класу та розміру сітки були доступні базові скани (позначення R0) без повороту. З метою збільшення обсягу навчальної вибірки та покращення узагальнювальних властивостей моделі було застосовано аугментацію даних шляхом повороту карт висот на фіксовані кути:  $90^\circ$ ,  $180^\circ$  та  $270^\circ$ . Це дозволило збільшити обсяг датасету вчетверо. Вибір саме ротаційної аугментації обґрунтований фізичним змістом задачі: орієнтація шматків руди на конвеєрі є довільною, тому модель повинна бути інваріантною до повороту.

Особливістю реальних даних є наявність характерних дефектів: пропуски значень висоти в окремих клітинках (через відсутність відбитого лазерного променя), нерівномірність поверхні шматків руди, артефакти сканування у вигляді одиничних викидів значень, а також шумові ефекти, пов'язані з властивостями поверхні матеріалу. Наявність цих дефектів значно ускладнює задачу класифікації, але водночас робить її більш реалістичною та практично значущою.




Рисунок 2 – Приклади реальних карт висот із дефектами для кожного з трьох класів

Загальна структура реального датасету включала зразки для трьох розмірностей сіток ( $32 \times 32$ ,  $64 \times 64$ ,  $128 \times 128$ ) та трьох класів (Single, United, Overlapped). Після ауг-

ментації загальний обсяг датасету склав кілька тисяч зразків, що є достатнім для навчання нейронних мереж середньої складності. Розбиття на тренувальну та валідаційну вибірки здійснювалося у співвідношенні 70/30 із збереженням пропорцій класів (stratified split).

#### 4. Дослідження впливу розмірності карти висот

Розмірність карти висот є ключовим гіперпараметром, що визначає баланс між деталізацією просторової інформації та складністю задачі класифікації. Більша розмірність сітки дозволяє зберегти більше дрібних деталей геометрії об'єктів, проте одночасно збільшує розмір вхідного тензора та кількість параметрів моделі, що може призводити до перенавчання при обмеженому обсязі даних.

У рамках дослідження було проведено порівняльні експерименти для трьох варіантів розмірності:  $32 \times 32$ ,  $64 \times 64$  та  $128 \times 128$ . Для кожної розмірності навчалися ідентичні архітектури нейронних мереж (поглиблена CNN) з однаковими гіперпараметрами навчання. Ключові результати наведено нижче.

Для розмірності  $32 \times 32$  спостерігалася висока стабільність навчання та мінімальна різниця між тренувальною ( $\sim 0.94$ ) та валідаційною ( $\sim 0.91$ ) точністю. Це пояснюється порівняно невеликою кількістю вхідних параметрів та достатністю наявних даних для навчання. Для розмірності  $64 \times 64$  тренувальна точність зросла до  $\sim 0.98$ , а валідаційна – зменшилася до  $\sim 0.90$ . Спостерігається початкова ознака перенавчання. Для розмірності  $128 \times 128$  тренувальна точність залишалася високою ( $\sim 1.0$ ), тоді як валідаційна точність знизилася до  $\sim 0.85$ . Розрив між тренувальною та валідаційною точністю значно збільшився, що є явною ознакою перенавчання.

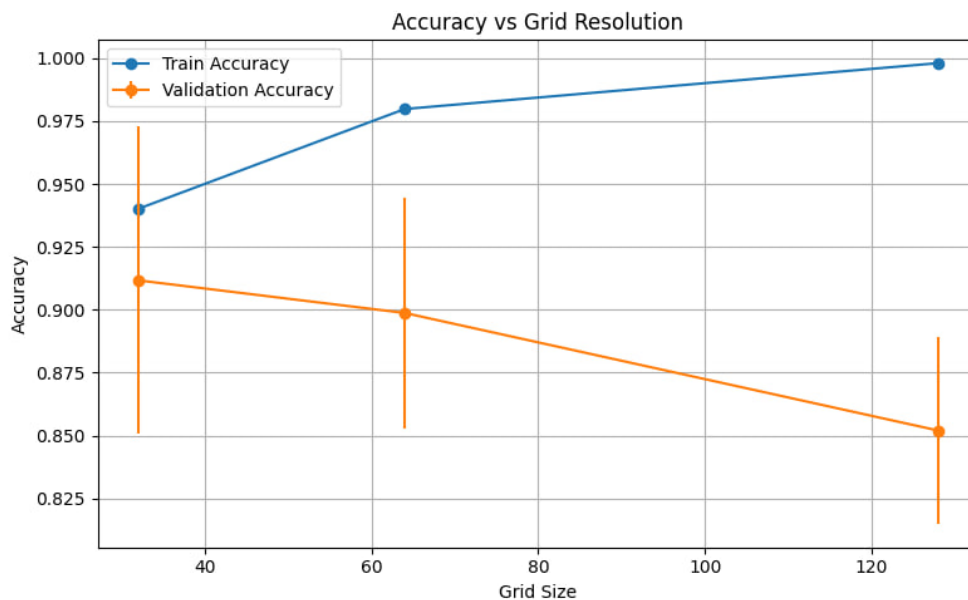


Рисунок 3 – Залежність точності класифікації від розмірності карти висот для тренувальної та валідаційної вибірок

Таким чином, розмірність  $64 \times 64$  забезпечує найкращий баланс між деталізацією просторової інформації та узагальнювальними властивостями моделі. Подальші дослідження проводилися переважно на даних розмірності  $64 \times 64$ .

## 5. Архітектури нейронних мереж

Для розв'язання задачі класифікації карт висот було розроблено та досліджено декілька архітектур нейронних мереж, від простих до складніших. Таким чином забезпечується можливість порівняльного аналізу та обґрунтування вибору оптимальної архітектури.

Базова багатошарова перцептронна мережа (MLP) – найпростіша архітектура, що не враховує просторову структуру даних. Карта висот перетворюється на одновимірний вектор (flatten), після чого послідовно з'єднуються кілька повнозв'язних шарів (Dense). Незважаючи на простоту, MLP слугує базовою лінією для порівняння більш складних підходів.

Базова CNN містить два згорткові блоки (Conv2D + MaxPooling), за якими слідує блок класифікації з повнозв'язними шарами. Згорткові шари дозволяють автоматично виявляти локальні просторові ознаки (границі об'єктів, піки висот, характерні геометричні структури), а шари підвибірки забезпечують просторову інваріантність та зменшення розмірності.

CNN із регуляризацією включає додаткові механізми для боротьби з перенавчанням: Dropout (відключення нейронів з ймовірністю 0.3–0.5 під час навчання) та L1-регуляризація ваг (Manhattan regularization). Ці методи обмежують складність моделі та покращують її узагальнювальні властивості.

Поглиблена CNN (Deep CNN) є основною запропонованою архітектурою. Вона включає три послідовні згорткові блоки з поступово збільшуваною кількістю фільтрів: Conv2D(16) → MaxPooling → Conv2D(32) → MaxPooling → Conv2D(64) → MaxPooling → Flatten → Dense(64) → Dense(3, softmax). Функція активації – ReLU у прихованих шарах, softmax – у вихідному. Функція втрат – categorical cross-entropy. Оптимізатор – Adam з початковою швидкістю навчання 0.001.




Рисунок 4 – Архітектура поглибленої CNN (Deep CNN) для класифікації карт висот

Поступове збільшення кількості фільтрів від 16 до 64 у наступних шарах відображає загальноприйнятий принцип проектування CNN: ранні шари виявляють прості низькорівневі ознаки (границі, градієнти), тоді як глибші шари навчаються розпізнавати більш складні просторові структури (форми об'єктів, характер поверхні, взаємне розташування пікових областей).

### 6. Результати навчання та порівняльний аналіз

Навчання всіх моделей проводилося з ідентичними умовами: при тестуванні різних архітектур нейронних мереж – розбиття даних 80/20, кількість епох – 20, розмір батчу – 16, оптимізатор Adam, а для тесту поглибленої CNN – розбиття даних 70/30, розмір батчу 32.

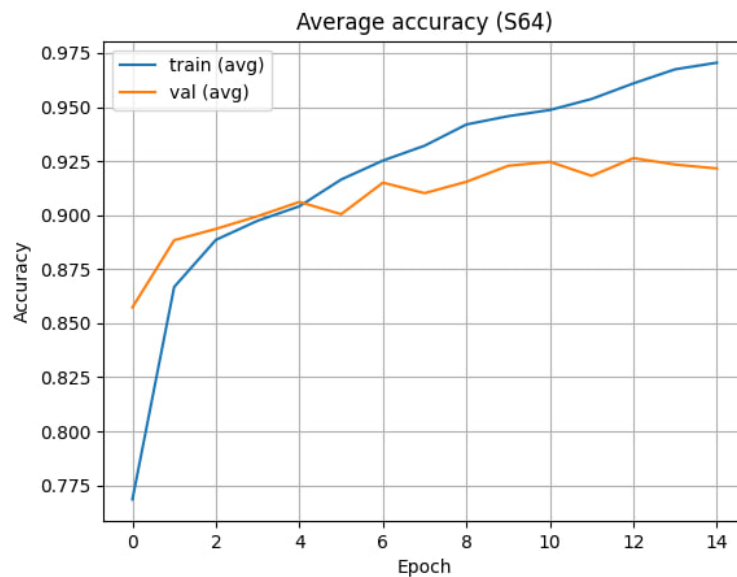


Рисунок 5 – Криві навчання поглибленої CNN: залежність точності та функції втрат від епохи навчання

Для датасету розмірності 64×64 на реальних даних отримано такі результати навчання: MLP – тренувальна точність 0.84, валідаційна точність 0.63; базова CNN – тренувальна точність 0.98, валідаційна точність 0.83; CNN+Dropout – тренувальна точність 0.91, валідаційна точність 0.89; CNN+L1 – тренувальна точність 0.72, валідаційна точність 0.75; поглиблена CNN – тренувальна точність 1.0, валідаційна точність 0.92.

Поглиблена CNN демонструє найвищу точність класифікації (92% на валідаційній вибірці), що на 9% перевищує результати базової CNN та на 29% – результати MLP. Це підтверджує перевагу глибших архітектур для задач просторового аналізу. Разом з тим відзначається, що використання Dropout дозволяє суттєво зменшити різницю між тренувальною та валідаційною точністю (з 8% до 2%), хоча абсолютне значення валідаційної точності при цьому дещо нижче, ніж у Deep CNN.

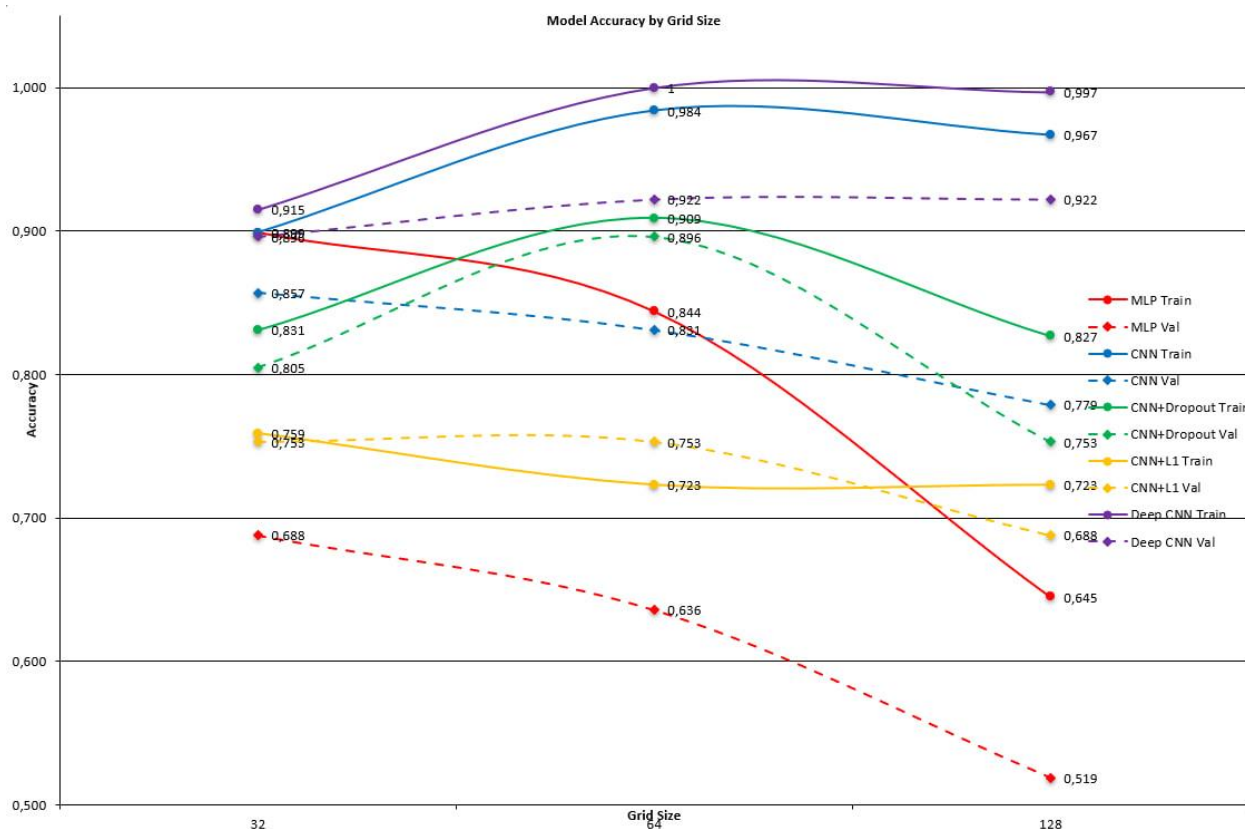


Рисунок 6 – Порівняння точності різних архітектур нейронних мереж на тренувальній та валідаційній вибірці

Аналіз кривих навчання поглибленої CNN виявляє характерну поведінку: швидке зростання точності в перших 8 епохах, поступова стабілізація після 9 епохи, незначні осциляції на пізніх стадіях навчання (що є нормальним явищем для задач із реальними, зашумленими даними). Функція втрат на валідаційній вибірці зменшується стійко протягом усього навчання, хоча дещо повільніше, ніж на тренувальній, що свідчить про помірне перенавчання.

Аналіз помилок класифікації показав, що найчастіше плутаються класи United та Overlapped. Це є логічним результатом, оскільки в граничних випадках (незначне перекриття) відмінність між цими станами є мінімальною навіть для людського спостерігача. Клас Single розпізнається найбільш надійно – точність розпізнавання цього класу перевищує 95% у всіх досліджених архітектурах.

**Висновки.** У роботі розроблено та досліджено підхід до автоматичної класифікації просторових станів об'єктів (одиначний, об'єднаний, накладений) на основі карт висот, сформованих із даних лазерного сканування, із використанням згорткових нейронних мереж. Проведено комплексне порівняльне дослідження п'яти архітектур нейронних мереж та визначено вплив розмірності карти висот на якість класифікації.

За результатами проведених досліджень сформульовано такі висновки:

1. Підхід до перетворення тривимірних хмар точок у двовимірні карти висот шляхом проєктування із збереженням максимального значення висоти є ефективним мето-

дом представлення просторової інформації для задач класифікації. Такі карти висот є інваріантними до оптичних властивостей поверхні та умов освітлення, що є важливою перевагою для промислових застосувань.

2. Поглиблена CNN (3 згорткові блоки з поступово збільшуваною кількістю фільтрів 16→32→64) забезпечує найвищу точність класифікації серед досліджених архітектур: до 100% на тренувальній та до 92% на валідаційній вибірці для реальних даних розмірності 64×64. Це на 29 відсоткових пунктів перевищує результати базового MLP.

3. Розмірність карти висот суттєво впливає на якість класифікації. Оптимальною виявилася розмірність 64×64, що забезпечує найкращий баланс між деталізацією просторової інформації та узагальнювальними властивостями моделі. Збільшення розмірності до 128×128 призводить до зростання перенавчання та зниження валідаційної точності.

4. Реальні дані лазерного сканування характеризуються наявністю дефектів (пропуски значень, шуми, артефакти), що значно ускладнює класифікацію порівняно із синтетичними даними. Аугментація за рахунок ротаційних перетворень (0°, 90°, 180°, 270°) дозволяє покращити узагальнювальні властивості моделі та забезпечити інваріантність до орієнтації об'єктів.

5. Найбільш складним для класифікації є розрізнення класів United та Overlapped у граничних випадках. Це вказує на необхідність або збільшення обсягу навчальних даних для цих граничних станів, або використання додаткових ознак (наприклад, розподіл висот у гістограмі або моменти поверхні).

Отримані результати підтверджують ефективність застосування CNN для аналізу карт висот у задачах прецизійного сенсорного сортування руд та можуть бути використані як основа для розробки реальних систем інтелектуального керування процесом сортування. Напрямами подальших досліджень є: крос-датасетна валідація, дослідження архітектур ResNet та EfficientNet, розробка методів виявлення граничних та аномальних ситуацій, а також оптимізація моделей для роботи в режимі реального часу.

#### ЛІТЕРАТУРА

1. Chalapathy R., Chawla S. Deep Learning for Anomaly Detection: A Survey // ACM Computing Surveys. – 2019. – Vol. 51, No. 5. – P. 1–48. – DOI: 10.1145/3299869. URL: <https://arxiv.org/abs/1901.03407>
2. Gholami A., Kim S., Dong Z., Yao Z., Mahoney M. W., Keutzer K. A Survey of Quantization Methods for Efficient Neural Network Inference // Low-Power Computer Vision. – 2021. – P. 291–326. – DOI: 10.1201/9781003162810-13. – URL: <https://arxiv.org/abs/2103.13630>
3. Parisi G. I., Kemker R., Part J. L., Kanan C., Wermter S. Continual Lifelong Learning with Neural Networks: A Review // Neural Networks. – 2019. – Vol. 113. – P. 54–71. DOI: 10.1016/j.neunet.2019.01.012. – URL: <https://arxiv.org/abs/1802.07569>
4. Peukert S., Heinig T., Tolosana-Delgado R., Bachmann K., Gutzmer J. A Review of Sensor-Based Sorting in Mineral Processing: The Potential and Limitations of Sensing and Data Processing // Minerals. – 2022. – Vol. 12, No. 11. – P. 1364. – DOI: 10.3390/min12111364. – URL: <https://www.mdpi.com/2075-163X/12/11/1364>

5. Qi C. R., Yi L., Su H., Guibas L. J. PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space // Proceedings of NeurIPS. – 2017. – P. 5099–5108.

URL: <https://arxiv.org/abs/1706.02413>

6. Rai S., Nistala S. H., Danda A. K., Sreenivas T. Application of Machine Learning Algorithms for Mineral Classification from Hyperspectral Data // Minerals Engineering. – 2021. – Vol. 170. – P. 107054. – DOI: 10.1016/j.mineng.2021.107054.

URL: <https://www.sciencedirect.com/science/article/abs/pii/S0892687521002636>

7. Robben C., Wotruba H. Sensor-Based Ore Sorting Technology in Mining—Past, Present and Future // Minerals. – 2019. – Vol. 9, No. 9. – P. 523. – DOI: 10.3390/min9090523.

URL: <https://www.mdpi.com/2075-163X/9/9/523>

8. Wang M., Deng W. Deep Visual Domain Adaptation: A Survey // Neurocomputing. – 2018. – Vol. 312. – P. 135–153. – DOI: 10.1016/j.neucom.2018.05.083.

URL: <https://arxiv.org/abs/1802.03601>

### REFERENCES

1. Chalapathy R., Chawla S. Deep Learning for Anomaly Detection: A Survey // ACM Computing Surveys. – 2019. – Vol. 51, No. 5. – P. 1–48. – DOI: 10.1145/3299869. – URL: <https://arxiv.org/abs/1901.03407>

2. Gholami A., Kim S., Dong Z., Yao Z., Mahoney M. W., Keutzer K. A Survey of Quantization Methods for Efficient Neural Network Inference // Low-Power Computer Vision. – 2021. – P. 291–326. – DOI: 10.1201/9781003162810-13. – URL: <https://arxiv.org/abs/2103.13630>

3. Parisi G. I., Kemker R., Part J. L., Kanan C., Wermter S. Continual Lifelong Learning with Neural Networks: A Review // Neural Networks. – 2019. – Vol. 113. – P. 54–71. – DOI: 10.1016/j.neunet.2019.01.012. – URL: <https://arxiv.org/abs/1802.07569>

4. Peukert S., Heinig T., Tolosana-Delgado R., Bachmann K., Gutzmer J. A Review of Sensor-Based Sorting in Mineral Processing: The Potential and Limitations of Sensing and Data Processing // Minerals. – 2022. – Vol. 12, No. 11. – P. 1364. – DOI: 10.3390/min12111364.

URL: <https://www.mdpi.com/2075-163X/12/11/1364>

5. Qi C. R., Yi L., Su H., Guibas L. J. PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space // Proceedings of NeurIPS. – 2017. – P. 5099–5108.

URL: <https://arxiv.org/abs/1706.02413>

6. Rai S., Nistala S. H., Danda A. K., Sreenivas T. Application of Machine Learning Algorithms for Mineral Classification from Hyperspectral Data // Minerals Engineering. – 2021. – Vol. 170. – P. 107054. – DOI: 10.1016/j.mineng.2021.107054.

URL: <https://www.sciencedirect.com/science/article/abs/pii/S0892687521002636>

7. Robben C., Wotruba H. Sensor-Based Ore Sorting Technology in Mining—Past, Present and Future // Minerals. – 2019. – Vol. 9, No. 9. – P. 523. – DOI: 10.3390/min9090523. – URL: <https://www.mdpi.com/2075-163X/9/9/523>

8. Wang M., Deng W. Deep Visual Domain Adaptation: A Survey // Neurocomputing. – 2018. – Vol. 312. – P. 135–153. – DOI: 10.1016/j.neucom.2018.05.083.

URL: <https://arxiv.org/abs/1802.03601>

Received 07.04.2026.

Accepted 09.04.2026.

Published 30.04.2026

***Classification of spatial states of objects based on height maps  
using convulsive neural networks for sensory sorting systems of ores***

*The article considers the problem of automatic classification of spatial states of objects in precision sensory sorting systems of ore raw materials. The relevance of the study is due to the limited effectiveness of traditional segmentation algorithms in conditions of overlapping and approaching pieces of ore on the conveyor. The aim of the work is to develop and study an approach to classifying three spatial states of objects (single, combined, superimposed) based on height maps obtained using laser scanning. Convolutional neural networks (CNN) are used as the research method. A comparative analysis of MLP, basic CNN, CNN with regularization and deep CNN architectures is carried out. The influence of the height map dimension (32×32, 64×64, 128×128) on the classification quality was investigated. It was found that the deep CNN demonstrates the best accuracy on real data – up to 90% on the validation sample with a dimension of 64×64. The effect of overtraining was revealed when the input data dimension increased. The obtained results confirm the promising application of CNN for the analysis of height maps in the tasks of intelligent control of the sorting process.*

*Keywords: sensory sorting of ores, height map, laser scanning, convolutional neural network, image classification, machine learning, precision sorting, point cloud, overtraining, data augmentation.*

**Кондрашов Дмитро Андрійович** – аспірант кафедри автоматизації, комп’ютерних наук і технологій, Криворізький національний університет, Кривий Ріг, Україна.

ORCID: <https://orcid.org/0009-0008-6751-925X>

**Музыка Іван Олегович** – к.т.н., доцент, кафедра комп’ютерних систем та мереж, Криворізький національний університет, Кривий Ріг, Україна.

ORCID: <https://orcid.org/0000-0002-9202-2973>

**Купін Андрій Іванович** – д.т.н., професор, кафедра комп’ютерних систем та мереж, Криворізький національний університет, Кривий Ріг, Україна.

ORCID: <http://orcid.org/0000-0001-7569-1721>

**Балик Дмитро Костянтинівич** – інженер-програміст, ТОВ «НВП Гамаюн».

ORCID: <http://orcid.org/0009-0000-4768-8576>

**Kondrashov Dmytro** – PhD Student, Department of Automation, Computer Sciences and Technology, Kryvyi Rih National University, Ukraine.

ORCID: <https://orcid.org/0009-0008-6751-925X>

**Muzyka Ivan** – Associate Professor, Department of Computer Systems and Networks, Kryvyi Rih National University, Kryvyi Rih, Ukraine.

ORCID: <https://orcid.org/0000-0002-9202-2973>

**Kupin Andrii** – Doctor of Technical Sciences, Professor, Department of Computer Systems and Networks, Kryvyi Rih National University, Kryvyi Rih, Ukraine.

ORCID: <http://orcid.org/0000-0001-7569-1721>

**Balyk Dmytro** – “SPE Hamaiun” LLC.

ORCID: <http://orcid.org/0009-0000-4768-8576>