

С.В. БІЛАШЕНКО, асистент, Н.Н. ШАПОВАЛОВА,  
О.Г. РИБАЛЬЧЕНКО, старші викладачі  
Криворізький національний університет

## РОЗПІЗНАВАННЯ ЗОБРАЖЕНЬ ЗА ДОПОМОГОЮ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ З ВИКОРИСТАННЯМ БІБЛІОТЕКИ KERAS

**Мета** роботи полягає у дослідженні архітектури глибокої згорткової нейронної мережі для розпізнавання зображень, розробці алгоритму її реалізації. В ході числового експерименту необхідно обґрунтувати підбір оптимальних гіперпараметрів експлуатації моделі: швидкості навчання, кількості шарів у мережі, кількості нейронів у прихованому шарі.

**Методи.** В ході дослідження використано метод аналізу вхідних даних, заснований на властивостях рецептивних полів біологічних нейронів, метод синтезу конвергуючих каскадів, що призводять до повноз'єднаних шарів штучної нейронної мережі, практичний метод використання певної архітектури моделі для розпізнавання зображень, емпіричний метод встановлення оптимальних значень основних гіперпараметрів навчання згорткової нейронної мережі.

**Наукова новизна.** Запропоновано алгоритм реалізації глибокої згорткової нейронної мережі, обґрунтовано вибір навчальної множини, що відповідає критерію достатньої репрезентативності, теоретично і практично обґрунтовано підбір оптимальних гіперпараметрів навчання мережі за критерієм якості експлуатації моделі.

**Практична значимість** виконаної роботи полягає в поліпшенні якості навчання глибоких згорткових нейронних мереж, розробці методики побудови програмної моделі системи розпізнавання зображень з використанням бібліотеки Keras для мови програмування Python 3, яка демонструє процес навчання і розпізнавання, а також дозволяє виконувати дослідження роботи згорткової нейронної мережі.

**Результати.** Розроблено структуру штучної згорткової нейромережі, запропоновано методику побудови моделі вхідних даних та поетапної реалізації каскадів прихованих шарів мережі, алгоритм її навчання, обґрунтовано вибір навчальної вибірки. Запропоновано програмну модель згорткової нейронної мережі розпізнавання зображень на основі методів бібліотеки Keras, реалізованою мовою програмування Python 3, яка дозволила емпірично визначити основні оптимальні параметри навчання моделі такі як швидкість навчання, кількості шарів у мережі і кількості нейронів у прихованому шарі.

**Ключові слова:** згорткові нейронні мережі, глибоке навчання, розпізнавання зображень, архітектура глибоких згорткових нейронних мереж, бібліотека Keras, набір даних CIFAR-10.

doi: 10.31721/2306-5435-2018-1-103-147-153

**Проблема та її зв'язок з науковими і практичними задачами.** Розпізнавання образів – процес віднесення об'єкта з фіксованою групою його властивостей до одного об'єкту з множини образів за задалегідь обумовленими правилами.

Розпізнавання об'єктів, як прикладна задача, знаходить широке використання у багатьох сферах діяльності людини: технічна діагностика; медична діагностика; біометрія; системи; обробка текстів; біоінформатика; прогнозування; робототехніка.

Одним з сучасних прогресивних методів вирішення задачі розпізнавання об'єктів є застосування нейронних мереж. Слід зазначити, що теорія та практика навчання нейронних мереж в наші дні бурхливо розвивається. Це викликано успішним застосуванням методів глибокого навчання. На основі цієї парадигми навчання нейронні мережі третього покоління позбулися ряду проблем, що стримували поширення та застосування традиційних нейронних мереж. Мережі, навчені за допомогою алгоритмів глибокого навчання, перевершили за точністю кращі альтернативні підходи, особливо при розпізнаванні зображень та аналізі текстової інформації [1].

**Аналіз досліджень і публікацій.** Штучні нейронні мережі являють собою математичну модель функціонування біологічних нейронних мереж – мереж нервових клітин живого організму. Як і в біологічній нейронній мережі, основним елементом штучної нейронної мережі є нейрон. Сполучені між собою нейрони, утворюють шари, кількість яких може варіюватися в залежності від складності нейронної мережі і вирішуваних нею завдань. Теоретичні основи програмування таких нейронних мереж, описуються у багатьох роботах [2, 3, 4].

Штучна нейронна мережа з декількома прихованими шарами – це глибока нейронна мережа (ГНМ). Подібно до звичайних нейронних мереж, ГНМ можуть моделювати складні нелінійні відносини між елементами.

Перевагою нейронних мереж перед традиційними алгоритмами є можливість їх навчання.

У процесі навчання ГНМ отримувана модель намагається представити об'єкт у вигляді комбінації простих примітивів. Додаткові шари дозволяють будувати абстракції все більш високих рівнів, що дає можливість створювати моделі для розпізнавання складних об'єктів реального світу. Найчастіше ГНМ будуються як мережі прямого поширення. Однак останні дослідження показали можливість застосування техніки глибокого навчання – це підмножина алгоритмічних методів, які базуються на аналогії зі структурою нейронів мозку людини [5]. Ці методи намагаються моделювати високорівневі абстракції у даних, використовуючи архітектури, що складаються з безлічі нелінійних трансформацій.

Для вирішення завдань на основі нейронної мережі розробникам потрібно: вибрати відповідну модель мережі; визначити топологію мережі (число елементів та їх зв'язки); вказати параметри навчання.

Для класифікації зображень добре підходять згорткові нейронні мережі (ЗНМ) – клас ГНМ прямого поширення. Їх реалізація базується на спеціальній архітектурі, інспірованої даними, які отримані у фізіологічних експериментах із зоровою корою. ЗНМ побудовані на використанні одного із різновидів багат шарових перцептронів, який розроблений таким чином, щоб мінімізувати обсяг попередньої обробки вхідної інформації [6]. Навчання ЗНМ відноситься до типу задач навчання «з учителем». У цій схемі система навчається розпізнавати образи за допомогою різного роду адаптивних схем. Розпізнавання за такою схемою характеризується тим, що заздалегідь відома правильна класифікація кожного навчаючого образу [7].

Топологія ЗНМ, запропонована Яном ЛеКуном [8] полягає в чергуванні згорткових шарів, субдискретизуючих шарів і наявності повнозв'язних шарів на виході. Така архітектура містить три основних парадигми: локальне сприйняття, розподілені ваги і субдискретизацію. Локальне сприйняття полягає в тому, що на вхід одного нейрона подається не все зображення, а лише деяка його область. Концепція розподілених ваг припускає, що для великої кількості зв'язків використовується дуже невеликий набір ваг. Суть субдискретизації полягає в зменшенні просторової розмірності зображення. Чергування шарів дозволяє складати карти ознак з карт ознак, що на практиці означає здатність розпізнавання складних ієрархій ознак.

Щодо основних гіперпараметрів ЗНМ, а саме швидкості навчання і кількості нейронів у шарі мережі, то ці параметри підбираються дослідником емпіричним шляхом, або використовуються значення вже широковідомих, добре протестованих мереж з аналогічною архітектурою. Швидкість навчання не є постійною величиною, а лінійно зменшується зі збільшенням числа ітерацій. Вона визначає швидкість зменшення величини корекції ваг [9]. Визначення кількості нейронів у шарі – дуже важливий етап в застосуванні ГНМ. В даний час немає ніяких жорстких правил ні для вибору кількості прихованих шарів, ні для вибору кількості нейронів в них. Занадто мала кількість не дозволить мережі навчитися. Занадто велика спричинить збільшення часу навчання мережі до фактично нереального значення [11], або призведе до перенавчання мережі.

**Постановка завдання.** Необхідно віднести об'єкт з фіксованою групою його властивостей до одного об'єкту з множини образів за заздалегідь обумовленим правилом. В якості алгоритму класифікації зображень буде використано модель ЗНМ.

Згорткова мережа може бути описана наступним рівнянням

$$(f * g)[m, n] = \sum_{k, l} f[m - k, n - l] \cdot g[k, l],$$

де  $f$  – початкова матриця зображення;  $g$  – ядро (матриця) згортки; символом  $*$  позначена операція згортки.

Модель ЗНМ складається з трьох типів шарів: згортковий, підвибірковий та повноз'єднаний. Типова архітектура згорткової нейронної мережі подана на рис.1.

Згортковий шар нейронної мережі реалізує ідею локальних рецептивних полів, при цьому кожний вихідний нейрон сполучений лише з певною (невеликою) областю вхідної матриці, моделюючи таким чином деякі особливості людського зору.

У спрощеному вигляді цей згортковий шар можна описати наступним виразом  $x^l = f(x^{l-1} * k^l + b^l)$ , де  $x^l$  – вихід шару;  $f(\ )$  – функція активації;  $k^l$  – коефіцієнт зрушення; символом  $*$  позначена операція згортки входу  $x$  з ядром  $k$ .




Рис. 1. Типова архітектура ЗНМ

При цьому за рахунок крайових ефектів розмір вихідних матриць зменшується

$$x_j^l = f\left(\sum_i x_i^{l-1} * k_j^l + b_j^l\right),$$

де  $x_j^l$  – карта ознак  $j$ ;  $f()$  – функція активації;  $b_j$  – кое-

фіцієнт зрушення для карти ознак  $j$ ;  $k_j^l$  – ядро згортки з номером  $j$ ;  $x_i^{l-1}$  – карти ознак попереднього шару.

Функцією підвибіркового шару є зменшення розміру вхідної карти ознак (зазвичай вдвічі). Це можна здійснити різними способами: для усередненого пулінгу використовується середнє арифметичне значення відгуків у деякій області; при використанні max-пулінгу вся карта ознак розподіляється на комірки розміром  $2 \times 2$  елемента, серед яких обирають максимальні за значенням

$$x^l = f(a^l \cdot \text{subsample}(x^{l-1}) + b^l),$$

де  $x^l$  – вихід шару  $l$ ;  $f()$  – функція активації;  $a, b$  – коефіцієнти;  $\text{subsample}()$  – операція вибірки локальних максимальних значень.

Повноз'єднаний шар багатшарового перцептронну можна описати наступним співвідношенням

$$x_j^l = f\left(\sum_i x_i^{l-1} \cdot w_{ij}^{l-1} + b_j^{l-1}\right),$$

де  $x^l$  – вихід шару  $l$ ;  $f()$  – функція активації;  $b$  – коефіцієнт зрушення;  $w$  – матриця вагових коефіцієнтів.

Навчання глибоких нейронних мереж може бути здійснено за допомогою звичайного алгоритму зворотного поширення помилки. Існує велика кількість модифікацій даного алгоритму. Таким чином, може бути використано кілька правил налаштування ваг. Наприклад, навчання вагових коефіцієнтів  $w_{ij}(t)$  алгоритмом стохастичного градієнтного спуску

$$w_{ij}(t+1) = w_{ij}(t) + \eta \frac{\partial C}{\partial w_{ij}},$$

де  $\eta$  – стала для регулювання величини поточного кроку;  $C$  – функція втрат. Вибір функції втрат може бути обумовлений класом завдання машинного навчання (з учителем, без учителя, з підкріпленням) і функції активації.

Дослідимо етапи моделювання і навчання ЗНМ для розпізнавання об'єктів, використовуючи бібліотеку Keras, для мови програмування Python 3.

**Викладення матеріалу та результати.** У дослідженні пропонується використання ЗНМ, архітектура якої представлена на рис.2. За основу архітектури взята ЗНМ, запропонована Яном ЛеКуном у 1988 році [10]. Основна ідея такої архітектури полягає в наявності шарів, що чергуються, реалізуючи операції згортки та max-пулінгу. Операції згортки ґрунтуються на ретельно підібраних локальних рецептивних полях з вагами, що розділяються між декількома картами ознак. Останні шари мають приховані шари і функцію активації softmax у вихідному шарі.




Рис. 2. Архітектура ЗНМ

На вхід ЗНМ подається зображення з трьох каналів RGB, після чого розміщені декілька каскадів, які складаються із згорткових та субдискретизуючих шарів. Вихідний шар містить ймовірності належності зображення до того чи іншого класу. Запропонований варіант глибокої згорткової нейронної мережі складається з 8 шарів.

Порядок чергування шарів заданий у вигляді двох каскадів, що повторюються. Кожен каскад містить два шара згортки та один шар підвибірки.

Для навчання глибоких нейронних мереж часто використовується метод зворотного поширення помилки і градієнтний спуск через простоту реалізації і хорошу збіжність цих методів. Однак, при навчанні глибоких структур виникає кілька проблем, які особливо важливі при оптимізації функцій у просторі великої розмірності: кількість обчислювальних елементів, початкові умови для ваг мережі, а також константа регулювання величини кроку.

Крім того, алгоритм стохастичного градієнтного спуску відомий своєю проблемою зникаючого градієнта, яка полягає в ослабленні градієнта, а значить і швидкості навчання в міру поглиблення від останніх шарів мережі до початку мережі. Через це глибокі шари мережі дуже погано навчаються. Проте останнім часом замість функції активації вузла мережі виду сигмоїда в глибоких мережах використовують нелінійність виду ReLU (Rectified Linear Unit), функцію якої можна описати як  $\max(0, x)$ . Ця функція реалізує простий пороговий перехід в нулі. Обчислення сигмоїда та гіперболічного тангенсу потребує виконання ресурсномістких операцій, у той час, коли ReLU реалізується за допомогою порогового перетворення матриці активацій в нулі, ReLU не схильний до насичення. Глибока мережа з таким видом функції активації не має проблеми ослаблення градієнта і добре навчається градієнтним спуском.

До двох головних проблем ГНМ відносять ті ж проблеми, що виникають і при навчанні звичайних нейронних мереж: час навчання та перенавчання.

Глибокі структури більш схильні до перенавчання, оскільки, маючи більше шарів, які дозволяють моделювати високорівневі абстракції, мережа може “вивчити” рідкісні ситуації. У цьому випадку на допомогу приходять різні види регуляризації.

Dropout – це простий та ефективний метод регуляризації, який був запропонований в роботі [11]. Ідея метода полягає в тому, що в процесі навчання випадково із загальної мережі багаторазово виділяється деяка підмережа, оновлення ваг виконується тільки в межах цієї підмережі. Нейрони потрапляють в підмережу з ймовірністю  $p$ , яка має назву коефіцієнт дропаута. Застосування цього метода дозволяє запобігти перенавчанню згорткової нейронної мережі.

Детально розглянемо як реалізувати подібну глибоку згорткову нейронну мережу з використанням бібліотеки Keras для мови програмування Python 3.

Бібліотека Keras – інструмент глибокого навчання нейронних мереж. Це відкрита нейромережева бібліотека, яка є надбудовою над фреймворками DeepLearning4j, Tensorflow та Theano [12]. Вона націлена на оперативну роботу з мережами глибокого навчання, при цьому спроектована так, щоб бути компактною, модульною і розширюваною.

Вихідним будівельним блоком Keras є модель. У бібліотеці передбачені два способи з'єднання моделей: послідовна композиція та функціональна композиція.

Визначимо алгоритм реалізації глибокої згорткової нейронної мережі за допомогою бібліотеки Keras на мові програмування Python.

Завантаження комплекту даних CIFAR-10  $((X_{train}, y_{train}), (X_{test}, y_{test}) = \text{cifar10.load\_data}()$ .

Комплект даних CIFAR-10 складається з 60000 кольорових картинок розміром  $32 \times 32$  пікселя з трьома каналами (50000 зображень – навчальний набір, 10000 – тестовий набір), розподілених на 10 класів (літак, автомобіль, пташка, кішка, олень, собака, жаба, кінь, човен, вантажівка). Комплект підготований таким чином, що на зображенні представлений лише один об'єкт, при цьому відсутні перетини між класами. Цей набір даних часто використовується для перевірки ефективності алгоритмів машинного навчання.

Під час завантаження комплекту даних CIFAR-10 зображення розподіляються між двома наборами (набір для навчання та набір для тестування). Крім того, виділяються так звані мітки класів, що містять правильні відповіді, який саме об'єкт представлений на зображенні.

Обробка даних. Виконаємо перетворення даних до категоріального виду (мітки класів містяться в категорії). Відомості про інтенсивність пікселів перетворимо до формату з рухомою точкою та нормалізуємо.

Створення моделі мережі ( $model=Sequential()$ ). Для з'єднання моделі мережі будемо використовувати послідовну композицію, яка являє собою лінійний конвеєр (стек) шарів нейронної мережі.

Перші два шари згортки ( $Convolution2D$ ) мають по 32 згорткові фільтри розміру  $3 \times 3$ . У цих шарів розмір виходу такий самий, як і розмір входу, тобто  $32 \times 32$ . В якості функції активації (activation function) використаємо ReLU, що вносить нелінійність у модель.

Наступний шар підвиборки ( $MaxPooling2D$ ) має розмір блоку  $2 \times 2$  та регуляризацию з коефіцієнтом 25% ( $Dropout(0.25)$ ).

Другий каскад мережі складається з двох згорткових шарів ( $Convolution2D$ ), які мають по 64 згорткових фільтри розміром  $3 \times 3$ , та шару підвиборки ( $MaxPooling2D$ ) з розміром блоку  $2 \times 2$  та регуляризацию з коефіцієнтом 25% ( $Dropout(0.25)$ ). В якості функції активації також використовуємо ReLU.

Дані перетворюються з двовимірного формату в одновимірний за допомогою ( $Flatten()$ ) та передаються на повноз'єднаний шар ( $Dense()$ ), що складається з 512 нейронів. В цьому шарі в якості функції активації також використовуємо ReLU. Наступний шар – вихідний ( $Dense()$ ), що складеться з 10 нейронів. Для цього шару використовуємо функцію активації softmax, яка є узагальненням сигмоїди. Softmax «сплющує»  $k$ -розмірний вектор, що містить довільні дійсні числа, в  $k$ -розмірний вектор дійсних чисел з інтервалу  $[0, 1]$ . Між цими двома вихідними шарами застосовуємо регуляризацию з коефіцієнтом 50% ( $Dropout(0.5)$ ).

На останньому етапі отриману глибоку згорткову нейронну мережу потрібно скомпілювати, привести до вигляду, який може бути виконаний базовою бібліотекою (Theano або TensorFlow).

Перед компіляцією потрібно прийняти декілька рішень: вибрати оптимізатор, тобто конкретний алгоритм, який буде оновлювати ваги під час навчання моделі; вибрати цільову функцію, яку оптимізатор буде використовувати для навігації по простору вагів; оцінити якість навченої моделі.

В бібліотеці Keras в якості оптимізатора реалізовано швидкий варіант градієнтного спуска – стохастичний градієнтний спуск (СГС) та два модернізовані методи оптимізації – RMSprop та Adam. Обидва ці методи використовують поняття імпульсу на додачу до поняття прискорення, що використовує СГС. Результатом такої модернізації є більш швидка сходимость методів за рахунок збільшення обсягів обчислень.

Бібліотека Keras підтримує наступні цільові функції.

Середньоквадратична похибка (СКП) – це усереднена сума квадратів різниць між передбаченими та істинними значеннями. Якщо позначити  $\gamma$  вектор  $n$  передбачень, а  $Y$  – вектор  $n$  значень, що спостерігаються, то середньоквадратична похибка дорівнює

$$СКП = \frac{1}{n} \sum_{i=1}^n (\gamma - Y)^2 .$$

Бінарна перехресна ентропія (БПЕ). Якщо модель передбачає значення  $p$ , тоді як істинне значення дорівнює  $t$ , то бінарна перехресна ентропія дорівнює

$$БПЕ = -t \log(p) - (1 - t) \log(1 - p) .$$

Категоріальна перехресна ентропія – це логарифмічна втрата у випадку декількох класів. Якщо модель передбачає значення  $p_{ij}$ , тоді як істинне значення дорівнює  $t_{ij}$ , то категоріальна перехресна ентропія дорівнює

$$L_i = -\sum_j t_{i,j} \log(p_{i/j}) .$$

Ця цільова функція використовується для передбачення багатокласових міток. Вона за замовчуванням використовується разом із функцією активації softmax.

Бібліотека Keras підтримує наступні показники якості: вірність, тобто відношення кількості правильних передбачень до загальної кількості міток; точність, тобто частина правильних відповідей моделі; повнота, тобто доля виявлених істинних подій.

При компіляції моделі в якості цільової функції використаємо категоріальну перехресну ентропію (`categorical_crossentropy`), процес оптимізації виконаємо за допомогою стохастичного градієнтного спуска, параметри якого варіюються:  $SGD(lr=XXX, decay=1e-6, momentum=0.9, nesterov=True)$ , де  $lr$  – швидкість навчання мережі. В якості метрики вико-

ристаємо точність (ассигасу).

Для навчання скомпільованої моделі нейронної мережі використаємо функцію  $fit()$ , яка приймає наступні параметри:  $epochs$  (кількість періодів) – параметр, який враховує, скільки разів навчальний набір подавався моделі. На кожній ітерації оптимізатор намагається відкоригувати ваги для мінімізації цільової функції;  $batch\_size$ , – параметр, який враховує, скільки навчальних наборів має побачити оптимізатор перед тим, як оновить ваги.

Після того, як модель глибокої згорткової нейронної мережі навчена, її слід перевірити на тестовому наборі, який містить зображення, які раніше не пред'являлися. Це дає можливість отримати мінімальне значення, що досягається цільовою функцією, та найкраще значення показника якості. При цьому навчальний і тестовий набір не повинні перетинатися.

Оцінимо вплив гіперпараметрів на якість навчання ЗНМ.

Побудуємо графіки вірності в залежності від кількості епох і шарів в мережі (рис. 3).




Рис. 3. Графіки вірності в залежності від кількості епох ЗНМ на 20-ти і на 40-ка епохах навчання

Мережа досягає вірності 78.4% на тестовому наборі за 40 ітерацій.

На графіку (рис. 4) помітно, що достатньої вірності 98% можливо досягти при 128 нейронах у прихованому шарі.




Рис. 4. Графіки вірності в залежності від кількості нейронів у прихованому шарі

**Висновки та напрямок подальших досліджень.** Розроблено структуру штучної згорткової нейронної мережі, запропоновано методику її навчання, обґрунтовано вибір навчальної множини, що відповідає критерію достатньої репрезентативності. Запропоновано програмну модель системи розпізнавання зображень з використанням бібліотеки Keras для мови програмування Python 3, яка демонструє процес навчання і розпізнавання, а також дозволяє виконувати дослідження роботи згорткової нейронної мережі. Експериментально визначено, що для оптимальної роботи ЗНМ достатньо 128 нейронів у прихованому шарі на 40 епохах навчання. В ході

подальших досліджень отримані результати планується застосувати в експерименті розпізнавання об'єктів у потоковому відео.

### Список літератури

1. C. D. Manning «Computational Linguistics and Deep Learning» «Computational Linguistics», vol. 41, 2015
2. **Міронов І.С.**, Скурлаев С.В. Распознавание образов при помощи нейронной сети [Электронный ресурс]. URL: [http://confonline.susu.ru/index.php?option=com\\_content&view=article&id=57:2011-05-06-04-36-21&catid=16:-2----&Itemid=18](http://confonline.susu.ru/index.php?option=com_content&view=article&id=57:2011-05-06-04-36-21&catid=16:-2----&Itemid=18)
3. **Principe J.C.**, Euliano N.R., Lefebvre W.C. Neural and Adaptive Systems. Fundamentals Through Simulations. New York. John Wiley & Sons Inc. 2000.
4. **Luo F-L.**, Unbehauen R. Applied Neural Networks for Signal Processing. Cambridge University Press. 1998.
5. **Y. Bengio** «Learning Deep Architectures for AI», Found. Trends, vol. 2, 2009

6. Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov; 15(Jun):1929–1958, 2014.
7. Мерков А. Б. Распознавание образов. Построение и обучение вероятностных моделей. 2014. 238 с.
8. Y. LeCun, Y. Bengio «Convolutional Networks for Images, Speech, and Time-Series», Brain Theory Neural Networks, vol. 3361, 1995
9. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. Springer, 2014. — 739 p.
10. Шеремет А.И., Перепелица В.В., Денисова А.М. Проектирование нейронной сети для распознавания символов в программной среде MATLAB [Электронный ресурс]. URL: <http://nauka.zinet.info/13/sheremet.php>
11. Y. LeCun and Y. Bengio “Word-level training of a handwritten word recognizer based on convolutional neural networks” in IAPR (Eds), Proc. of the International Conference on Pattern Recognition, II:88-92, IEEE, Jerusalem, October 1994.
12. Антонио Джулли, Суджит Пал. Библиотека Keras – инструмент глубокого обучения. Реализация нейронных сетей с помощью библиотек Theano и TensorFlow/пер. с англ. Слинкин А. А. – М. : ДМК Пресс, 2018. – 294 с.

Рукопис подано до редакції 27.03.2018

УДК 622.807:621.928.9

О. Є. ЛАПШИН, д-р техн. наук, проф., М. В. ХУДИК, канд. техн. наук, ст. викладач  
Криворізький національний університет

## ОГЛЯД ІСНУЮЧИХ КОНСТРУКЦІЙ ПИЛООСАДЖУВАЛЬНИХ КАМЕР ДЛЯ ОЧИЩЕННЯ АСПІРАЦІЙНОГО ПОВІТРЯ

**Мета.** Метою даної роботи є аналіз існуючих конструктивних рішень при проектуванні пилоосаджувальних камер для знепилення аспіраційного повітря, яке видаляється від джерел виділення пилу. Переробка корисних копалин призводить до утворення та виділення у навколишнє середовище значної кількості промислового пилу. Для попередження поширення пилу у виробничих цехах, джерела виділення пилу обладнують аспіраційними укриттями, з яких запилене повітря видаляється до пилоочисних установок. Незадовільна робота пилоочисних агрегатів призводить до забруднення промислових майданчиків і території гірничо-збагачувальних комбінатів та шахт пилом погіршуючи санітарно-гігієнічні умови праці їх робітників

**Методи дослідження.** Використовувався аналіз та узагальнення літературних джерел, охоронних документів на винаходи та корисні моделі щодо типів та конструктивних рішень пилоосаджувальних камер для очищення аспіраційного повітря від пилу.

**Наукова новизна.** Розглянуто можливості підвищення ефективності пиловловлення промислового пилу з аспіраційного повітря пилоосаджувальними камерами за рахунок розміщення в них різних перешкод (горизонтальних або похилих полиць, напрямних пластин, вертикальних або горизонтальних перегоронок, волоконних завіс та ін.) для подальшої розробки та дослідження нової конструкції пилоосаджувальної камери.

**Практична значимість.** Проведений аналіз показав, що на ефективність пиловловлення пилоосаджувальної камери можливо впливати не тільки зміною геометричних розмірів камери (довжини, поперечного перерізу), а і за рахунок зміни параметрів пилових часток (діаметра). За рахунок укрупнення пилових часток можна досягти збільшення швидкості їх витання (осадження) і підвищення ефективності роботи пилоосаджувальної камери при сталих її геометричних розмірах.

**Результати.** Проведені дослідження різних конструкцій пилоосаджувальних камер показали доцільність розробки нової конструкції пилоосаджувальної камери підвищеної ефективності з розміщеними в середині камери волоконними завісами з капрону та полівінілхлориду. Така конструкція камери для очищення аспіраційного повітря дозволить поліпшити санітарно-гігієнічні умови праці робітників гірничо-збагачувальних комбінатів та шахт.

**Ключові слова:** пилоосаджувальна камера, аспіраційне повітря, уловлення пилу, коагуляція, волоконні завіси.

doi: 10.31721/2306-5435-2018-1-103-153-158

**Проблема та її зв'язок з науковими та практичними завданнями.** Промислова переробка корисних копалин (залізна руда, кам'яне вугілля, граніти та ін.) супроводжується утворенням значної кількості пилу на всіх технологічних етапах їх переробки (класифікація за крупністю, дроблення і подрібнення, транспортування, збагачення). При контакті з організмом людини, промисловий пил може викликати різні захворювання (алергічні реакції, катаракту, пневмоконіози). З метою запобігання розповсюдженню пилу у виробничих приміщеннях, місця виділення пилу локалізуються за допомогою аспіраційних укриттів з видаленням запиленого повітря у пилоочисні установки.

Класифікацію за крупністю (грохочення) корисних копалин використовують на дробильно-сортувальних та збагачувальних фабриках з метою їх розділення за величиною шматків за до-