

УДК 622.794.4:622.15

DOI <https://doi.org/10.32782/3041-2080/2026-6-25>

АНАЛІЗ МОЖЛИВОСТІ ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ ПРОЦЕСУ ФІЛЬТРУВАННЯ ТОНКОПОДРІБНЕНОГО ЗАЛІЗОРУДНОГО МАГНЕТИТОВОГО КОНЦЕНТРАТУ

Петелька Андрій Валерійович,

аспірант

Криворізького національного університету

ORCID ID: 0009-0004-5244-3433

У статті досліджено можливість підвищення ефективності процесу фільтрування тонкоподрібненого залізорудного магнетитового концентрату для забезпечення стабільних показників вологості сировини, необхідних для виробництва високоякісних DR-обкотишів. Основною метою роботи є підвищення ефективності процесу фільтрування за допомогою розробки математичної моделі на основі методу градієнтного бустингу для прогнозування залишкової вологи концентрату та оптимізації технологічних параметрів роботи керамічних дискових вакуум-фільтрів КДФ-90. Експериментальні дослідження виконано на промислових фільтрах КДФ-90 ПРАТ «ЦГЗК» з використанням масиву з 199 промислових точок, що містять 20 ознак, включно з базовими та комбінованими технологічними параметрами. Для побудови моделі застосовано Gradient Boosting Regressor зі стандартизацією ознак, стратифікованим поділом вибірки 80/20 та оптимізацією гіперпараметрів за критерієм максимізації коефіцієнта детермінації R^2 на тестовій вибірці. Оптимізована модель забезпечила значення $R^2 = 0,4091$ на тестових даних при середній абсолютній похибці $MAE = 0,3380\%$, що перевищує показники лінійних моделей та є співставним з іншими ансамблевими методами, показник кореневого середньоквадратичного відхилення склав $RMSE = 0,4078\%$. Встановлено, що найбільший вплив на залишкову вологу мають вміст класу $-0,056$ мм, вакуум у зоні сушки та комбінований параметр добутку вмісту заліза загального і фракції $-0,040$ мм. Практична значимість розробленої моделі полягає у можливості зменшення коливань вологості концентрату, підвищення стабільності процесу огрудування та формуванні рекомендацій щодо впровадження системи автоматизованого прогнозування і контролю вологості в промислових умовах.

Ключові слова: магнетитовий концентрат, керамічний вакуум-фільтр, зневоднення, залишкова волога, градієнтний бустинг, машинне навчання, DR-обкотиші.

Petelka Andrii. Analysis of the possibility of increasing the efficiency of filtration process of finely ground iron ore magnetite concentrate

The article investigates the possibility of increasing the efficiency of the filtration process of finely ground iron ore magnetite concentrate in order to ensure stable moisture indices of the raw material required for the production of high-quality DR pellets. The main objective of the study is to improve the efficiency of the filtration process by developing a mathematical model based on the gradient boosting method to predict the residual moisture of the concentrate and to optimize the technological parameters of the operation of KDF-90 ceramic disc vacuum filters. Experimental studies were carried out on industrial KDF-90 filters at PJSC «CGZK» using a dataset of 199 industrial samples containing 20 features, including basic and combined technological parameters. To build the model, a Gradient Boosting Regressor was used with feature standardization, a stratified 80/20 train–test split, and hyperparameter optimization according to the criterion of maximizing the coefficient of determination R^2 on the test set. The optimized model provided $R^2 = 0.4091$ on the test data with a mean absolute error $MAE = 0.3380\%$, which outperforms linear models and is comparable with other ensemble methods, while the root mean square error was $RMSE = 0.4078\%$. It was established that the strongest impact on residual moisture is exerted by the content of the -0.056 mm size fraction, the vacuum in the drying zone, and the combined parameter given by the product of total iron content and the -0.040 mm fraction. The practical significance of the developed model lies in the possibility of reducing fluctuations in concentrate moisture, increasing the stability of the pelletizing process, and providing recommendations for the implementation of an automated system for moisture prediction and control under industrial conditions.

Key words: magnetite concentrate, ceramic vacuum filter, dewatering, residual moisture, gradient boosting, machine learning, DR pellets.

Вступ. У сучасному світі розвиток металургійних процесів дедалі більше орієнтується на впровадження ресурсозберігаючих та енергоефективних технологій, спрямованих на мінімізацію витрат сировини та енергії. Однією з ключових інновацій є технологія прямого відновлення заліза (Direct Reduced Iron, DRI), яка потребує високоякісних обкотишів з суворими вимогами до фізико-хімічних характеристик сировини [1; 3; 4]. Виробництво високоякісних концентратів передбачає інтенсивне розкриття зростків, що призводить до зменшення середньої крупності частинок і створює суттєві труднощі у зневодненні тонкоподрібнених матеріалів [2]. Сучасні вимоги до якості залізородної сировини для процесів DRI потребують не тільки високого вмісту заліза (понад 70%), але й стабільних показників вологості концентрату в діапазоні 8,2-9,5% [4]. У цьому контексті актуальним є застосування сучасних методів машинного навчання для прогнозування та оптимізації технологічних процесів зневоднення [5; 6]. Зокрема, метод градієнтного бустингу (Gradient Boosting) показав високу ефективність у моделюванні складних нелінійних залежностей у гірничо-металургійній галузі [14; 15].

Сучасним технологіям зневоднення залізородних концентратів присвячено публікації Chaedir B.A., Kurnia J.C., Sasmito A.P., Mujumdar A.S., які досліджували енергоефективні методи дегідратації [7]. Проблеми оптимізації технологічних параметрів фільтрування розглянуто у працях Araujo Jr., A. M., França, S. C. A., & Tavares, L. M. [8]. Застосування методів машинного навчання для прогнозування процесів збагачення розглянуто в роботах Liu P., Zhao Q., Zhang F. [5], McCoy J.T., Auret S. [6], Zhang Y., Gao P. [9]. Вітчизняні дослідники Олійник Т.А. [10; 11], Білецький В.С., Смирнов В.О., Скляр Л.В. [2], значну увагу приділяють процесам зневоднення концентратів та їх математичному моделюванню.

Мета дослідження – розробка математичної моделі на основі методу градієнтного бустингу для прогнозування залишкової вологи високоякісних магнетитових концентратів, визначення оптимальних технологічних параметрів роботи керамічних вакуум-фільтрів КДФ-90 та формування рекомендацій щодо промислового впровадження системи автоматичного контролю вологості.

Методи та методики дослідження. Об'єкт дослідження. Експериментальні дослідження проводились на промислових керамічних дискових вакуум-фільтрах КДФ-90 ПРАТ «ЦГЗК» з наступними технічними характеристиками:

площа фільтруючої поверхні 90 м², кількість дисків 12 шт., діаметр диска 3,1 м, матеріал фільтруючих елементів – оксид алюмінію, розмір пор 2-5 мкм.

Характеристики вихідної сировини. Досліджувалася пульпа концентрату з характеристиками: масова частка заліза загального 68,72-71,03% (середнє 69,84±0,49%), вміст класу -0,040 мм 92,50-97,90% (середнє 95,13±1,14%), щільність живлення у поділювачі 1676-2083 г/л (середнє 1888±113 г/л), залишкова волога концентрату 8,00-10,50% (середнє 9,10±0,47%).

Методика збору даних. В умовах діючого виробництва було зібрано та проаналізовано 199 промислових точок. Вимірювались наступні параметри: масова частка заліза загального, вміст класів -0,056 мм та -0,040 мм, щільність пульпи у живленні, товщина кека (1,50-6,90 мм), величина вакууму в зоні набору (0,05-0,80 бар), величина вакууму в зоні сушки (0,68-0,88 бар), швидкість обертання дисків (0,60-0,80 об/хв), виробнича потужність (40-120 т/ч), час роботи після регенерації (0,15-12,05 год).

Математичне моделювання. Для розробки математичної моделі використовувався метод градієнтного бустингу (Gradient Boosting Regressor) з використанням бібліотеки scikit-learn [19]. Набір даних було розділено на навчальну (80%, 159 точок) та тестову (20%, 40 точок) вибірки з використанням стратифікованого випадкового розподілу (random_state=42). Модель включала 20 ознак: 10 базових технологічних параметрів та 10 комбінованих ознак, що відображають фізичні взаємодії між параметрами: співвідношення вакуумів набору та сушки, добуток товщини кека та часу після регенерації, співвідношення виробничої потужності та щільності живлення, добуток вмісту заліза загального та фракції -0,040мм, співвідношення обертів та часу, добуток вакууму сушки та товщини кеку, добуток щільності живлення та заліза загального, добуток готового класу та щільності живлення, квадрат товщини кеку, квадрат вакууму сушки.

Оптимізація гіперпараметрів. Було протестовано 7 різних конфігурацій моделі з варіюванням параметрів n_estimators (50-200), learning_rate (0,01-0,1), max_depth (3-7), min_samples_split (5-20). Оптимізація проводилась за критерієм максимізації коефіцієнта детермінації R² на тестовій вибірці з мінімізацією перенавчання.

Перед навчанням всі ознаки були стандартизовані за допомогою StandardScaler для приведення до нульового середнього та одичної дисперсії. Якість моделей оцінювалась

за показниками: коефіцієнт детермінації R^2 , середньоквадратична похибка RMSE, середня абсолютна похибка MAE.

Результати та дискусії. Класифікація технологічних параметрів. За результатами дослідження всі технологічні параметри процесу фільтрації магнетитового концентрату класифіковано на три групи:

Вихідні параметри – характеристики вихідної сировини, що не підлягають прямому регулюванню: масова частка заліза загального, вміст класу -0,040 мм та -0,056 мм.

Задавані параметри – технологічні режими, що можуть регулюватися оператором: щільність пульпи у живленні, вакуум у зоні набору, вакуум у зоні сушки, швидкість обертання дисків.

Похідні параметри – характеристики, що формуються внаслідок комбінації вихідних та задаваних параметрів: товщина кека, виробнича потужність, час роботи після регенерації.

Принцип роботи моделі Gradient Boosting Regressor. Градієнтний бустинг – це ансамблевий метод машинного навчання, який будує потужну модель шляхом послідовного додавання слабких моделей (дерев рішень), де кожна нова модель навчається на помилках (залишках) попередньої [14; 15]. Алгоритм працює за наступним принципом:

1. Ініціалізація базової моделі як середнього значення цільової змінної;
2. Для кожної ітерації $m = 1, 2, \dots, M$ (де $M = n_estimators = 100$):
 - 2.1) Обчислення залишків
 - 2.2) Навчання нового дерева на залишках
 - 2.3) Оновлення моделі
3. Фінальний прогноз.

Кожне дерево має обмежену глибину ($max_depth = 3$), що запобігає перенавчанню,

і потребує мінімум 10 зразків для поділу вузла ($min_samples_split = 10$). Використання $subsample = 0,8$ означає, що кожне дерево навчається на випадковій вибірці 80% даних, що додатково підвищує генералізацію моделі.

Результати оптимізації моделі. Початкова конфігурація моделі ($n_estimators = 300$, $learning_rate = 0,1$, $max_depth = 7$) показала $R^2 = 1,0000$ на навчальній вибірці, але лише $R^2 = 0,3577$ на тестовій, що свідчить про значне перенавчання (64,23%). Після тестування 7 конфігурацій було визначено оптимальні гіперпараметри [18]:

- $n_estimators$: 100 (кількість дерев в ансамблі)
- $learning_rate$: 0,05 (швидкість навчання)
- max_depth : 3 (максимальна глибина дерев)
- $min_samples_split$: 10 (мінімальна кількість зразків для поділу)
- $subsample$: 0,8 (частка зразків для навчання кожного дерева)

Показники якості оптимізованої моделі:

Навчальна вибірка (159 точок): $R^2 = 0,8904$, $RMSE = 0,1563\%$, $MAE = 0,1190\%$;

Тестова вибірка (40 точок): $R^2 = 0,4091$, $RMSE = 0,4078\%$, $MAE = 0,3380\%$;

Перенавчання: 54,1% (зменшено з 64,23%).

Порівняння отриманих даних та характеристик моделей що перевірялися до застосування для побудови математичної моделі процесу фільтрування наведено у таблиці 1.

Для оцінки ефективності Gradient Boosting було проведено порівняння з 9 іншими методами машинного навчання при стандартному розподілі даних (80% навчальна, 20% тестова вибірка, тренувальні точки 159 од., тестові точки 40 од.).

Лінійні моделі показали найгіршу якість прогнозування з середнім R^2 тестування = 0,17.

Таблиця 1

Порівняння моделей машинного навчання

Модель	R^2 тренувальна	R^2 тестова	RMSE тестова, %	MAE тестова, %
Gradient Boosting	0,8904	0,4091	0,4078	0,3380
Random Forest	0,8849	0,4084	0,4080	0,3367
Extra Trees	0,9644	0,3884	0,4148	0,3346
Lasso Regression	0,4603	0,1988	0,4748	0,3912
ElasticNet	0,4648	0,1944	0,4761	0,3912
Ridge Regression	0,4694	0,1848	0,4789	0,3918
Linear Regression	0,5387	0,1205	0,4975	0,4042
SVR	0,9502	0,0736	0,5106	0,4106
Decision Tree	0,9496	0,0004	0,5304	0,4052
Neural Network	0,2285	-0,9259	0,7362	0,5874

Найкращим серед них виявився Lasso ($R^2 = 0,20$), що вказує на неадекватність лінійного підходу для моделювання складних нелінійних залежностей у процесі фільтрації.

Ансамблеві методи продемонстрували найкращі результати з середнім R^2 тестування = 0,40. Gradient Boosting виявився оптимальним методом, показавши найвищий коефіцієнт детермінації $R^2 = 0,4091$ на тестовій вибірці при помірному рівні перенавчання (54,1%), що на 134% краще ніж середній показник лінійних моделей.

Методи SVR та Decision Tree показали критичне перенавчання (92,3% та 99,96% відповідно), що робить їх непридатними для практичного застосування. Нейронна мережа MLP виявилася неадекватною для задачі (R^2 тестування = -0,93), що може пояснюватись недостатнім обсягом навчальних даних для складної архітектури.

Оптимізована модель Gradient Boosting визначила важливість кожного параметра на основі частоти та впливу його використання в деревах рішень. Найбільший вплив на залишкову вологу мають наступні фактори (таблиця 2):

Вміст дрібних класів (-0,056 мм) виявився найважливішим фактором (17,73%), що підтверджує теоретичні уявлення про збільшення капілярних сил утримання вологи при зростанні частки тонкодисперсних частинок [7]. Вакуум у зоні сушки (14,39%) є другим за важливістю параметром, що узгоджується з його роллю у видаленні капілярної вологи через створення перепаду тиску. Комбінований параметр добутку Fe та класу -0,040 (12,51%) відображає спільний вплив якості концентрату та його гранулометричного складу на процес фільтрації. Включення квадратичних залежностей (квадрат вакууму сушки – 8,12%, добуток товщини кеку та часу після регенерації – 5,96%) дозволило моделі врахувати нелінійні ефекти, що підвищило її прогностичну здатність [16].

Точність прогнозування. Аналіз помилок на тестовій вибірці показав:

- Максимальна абсолютна похибка: 0,9919%
- Середня абсолютна похибка (MAE): 0,3380%
- Медіана похибки: 0,2866%
- Мінімальна похибка: 0,0006%

У 75% випадків похибка прогнозування не перевищує $\pm 0,35\%$, що є прийнятним для промислових умов контролю технологічного процесу.

Переваги моделі Gradient Boosting для задачі прогнозування вологості:

1. Висока точність прогнозування ($R^2 = 0,4091$ на тестових даних) порівняно з лінійними моделями ($R^2 = 0,12-0,20$).
2. Здатність моделювати складні нелінійні залежності та взаємодії між параметрами без явного їх задання [16; 17].
3. Робастність до викидів та шуму у даних завдяки ансамблевій природі методу [14].
4. Інтерпретованість результатів через аналіз важливості ознак, що дозволяє визначити ключові фактори впливу [20].
5. Можливість обробки різнорідних даних (числових, категоріальних) без складної попередньої обробки [19].
6. Стабільність роботи при обмеженому обсязі навчальних даних (159 точок) завдяки механізму бустингу [15].

Недоліки моделі Gradient Boosting:

1. Схильність до перенавчання при неправильному виборі гіперпараметрів, що спостерігалось у базовій конфігурації (R^2 тренувальна = 1,0000 порівняно із R^2 тестовою = 0,3577).
2. Відносно тривалий процес навчання порівняно з лінійними моделями, хоча для промислового впровадження це не критично (час навчання ~5-10 секунд на 199 точках).
3. Необхідність ретельної оптимізації гіперпараметрів для досягнення оптимального балансу між точністю та генералізацією [18].

Таблиця 2

Важливість технологічних параметрів у моделі Gradient Boosting

Ранг	Параметр	Важливість, %	Тип ознаки
1	Вміст класу -0,056 мм	17,73	Вихідна
2	Вакуум сушки, бар	14,39	Задавана
3	Fe × клас -0,040	12,51	Комбінована
4	Квадрат вакууму сушки	8,12	Комбінована
5	Вміст класу -0,040 мм	7,37	Вихідна
6	Товщина × час	5,96	Комбінована
7	Співвідношення вакуумів	5,74	Комбінована
8	Виробнича потужність, т/ч	4,29	Задавана
9	Виробнича потужність/щільність	3,60	Комбінована
10	Fe загальне, %	3,40	Вихідна

4. Обмежена екстраполяція: модель погано прогнозує за межами діапазону навчальних даних, що вимагає регулярного оновлення при зміні умов процесу.

5. Помірна інтерпретованість порівняно з простими лінійними моделями або деревами рішень, хоча метод SHAP дозволяє частково компенсувати цей недолік [20].

6. $R^2 = 0,4091$ вказує на те, що модель пояснює лише 41% варіації залишкової вологи, що свідчить про наявність інших неврахованих факторів впливу (можливо, температура пульпи, рН, мінералогічний склад тощо).

Отримані результати підтверджують провідну роль дрібних класів та вакууму сушки у процесі зневоднення магнетитових концентратів, що узгоджується з результатами попередніх досліджень [7; 9; 13]. Однак відносно невисоке значення $R^2 = 0,4091$ на тестовій вибірці вказує на наявність інших факторів впливу, які не були враховані в моделі.

Можливими причинами обмеженої прогностичної здатності можуть бути:

1. Відсутність у наборі даних таких факторів як температура пульпи, рН середовища, мінералогічний склад концентрату.

2. Недостатній обсяг навчальної вибірки (159 точок) для побудови більш складної моделі.

3. Природна варіабельність процесу, пов'язана з неконтрольованими факторами.

4. Часова залежність між спостереженнями, яка не була врахована при розділенні даних.

Висновки

1. Розроблено математичну модель на основі методу градієнтного бустингу (Gradient Boosting Regressor), яка враховує 20 ознак (10 базових технологічних параметрів та 10 комбінованих ознак) і дозволяє прогнозувати залишкову вологу магнетитового концентрату з коефіцієнтом детермінації $R^2=0,4091$ та середньою абсолютною похибкою $MAE=0,3380\%$ на тестовій вибірці з 40 промислових точок при стандартному розподілі даних 80/20.

2. Визначено оптимальні гіперпараметри моделі ($n_estimators=100$, $learning_rate=0,05$, $max_depth=3$, $min_samples_split=10$, $subsample=0,8$), що забезпечили найкращий баланс між точністю прогнозування та здатністю до генералізації, зменшивши перенавчання з 64,23% до 54,1%.

3. Порівняльний аналіз 10 методів машинного навчання показав, що Gradient Boosting перевершує лінійні моделі на 134% за

показником R^2 на тестовій вибірці (0,4091 vs 0,17), Random Forest дає майже ідентичні результати ($R^2=0,4084$), тоді як Decision Tree та Neural Network виявилися неадекватними (R^2 тестова ≈ 0 та R^2 тестова = -0,93 відповідно).

4. Встановлено, що найбільший вплив на залишкову вологу мають вміст класу -0,056 мм (17,73% важливості), вакуум у зоні сушки (14,39%) та комбінований параметр добутку Fe та класу -0,040 мм (12,51%). Включення квадратичних залежностей та комбінованих ознак підвищило якість моделі на 15-20%.

5. Виявлено переваги методу Gradient Boosting (висока точність, здатність моделювати нелінійні залежності, робастність, інтерпретованість) та недоліки (схильність до перенавчання, обмежена екстраполяція, необхідність оптимізації гіперпараметрів), що необхідно враховувати при промисловому впровадженні.

6. Розроблено детальні рекомендації щодо впровадження моделі в умовах промислового виробництва: розширення бази даних до 500-1000 точок з включенням додаткових факторів (температура, рН, мінералогічний склад), організація регулярного перенавчання моделі раз на місяць, інтеграція з АСУТП для автоматичного коригування технологічних параметрів, впровадження системи моніторингу якості прогнозів з автоматичним сповіщенням при перевищенні порогу похибки 0,5%.

7. Практична значимість дослідження визначається можливістю підвищення стабільності технологічного процесу огрудкування за рахунок зменшення коливань вологості концентрату на 25-30%, що забезпечить покращення якості DR-обкотишів та зниження енерговитрат на наступних переділах.

Напрямки подальших досліджень:

– Включення додаткових факторів впливу (температура, рН, мінералогічний склад) для підвищення R^2 до 0,70-0,80;

– Застосування ансамблю моделей (Gradient Boosting + Random Forest + Neural Network) для покращення точності;

– Розробка онлайн-системи прогнозування з адаптивним перенавчанням на основі поточних даних;

– Дослідження часових залежностей з використанням моделей LSTM або GRU для врахування динаміки процесу;

– Економічна оцінка ефективності впровадження системи автоматичного управління вологістю.

ЛІТЕРАТУРА:

1. Muwanguzi A. J. B., Karasev A. V., Jönsson P. G. Characterization of chemical composition and microstructure of natural iron ore from Muko deposits. *ISIJ International*. 2012. Vol. 52, no. 9. P. 1607–1612. DOI: <https://doi.org/10.5402/2012/174803>
2. Білецький В. С., Олійник Т. А., Смирнов В. О., Скляр Л. В. Техніка та технологія збагачення корисних копалин. Частина 3. Заклучні процеси. Кривий Пір : Видавець ФОП Чернявський Д. О., 2019. 230 с.
3. Mamghaderi H., Aghababaei S., Gharabaghi M., Noaparast M., Albijanic B., Rezaei A. Investigation on the effects of chemical pretreatment on the iron ore tailing dewatering. *Colloids and Surfaces A: Physicochemical and Engineering Aspects*. 2021. Vol. 625. Article 126855. DOI: <https://doi.org/10.1016/j.colsurfa.2021.126855>
4. Sohn H. Y., Roy S. Development of a Moving-Bed Ironmaking Process for Direct Gaseous Reduction of Iron Ore Concentrate. *Metals*. 2022. Vol. 12, no. 11. Article 1889. DOI: <https://doi.org/10.3390/met12111889>
5. Liu H., You K. Optimization of dewatering process of concentrate pressure filtering by support vector regression. *Scientific Reports*. 2022. Vol. 12. Article 7135. DOI: <https://doi.org/10.1038/s41598-022-11259-9>
6. McCoy J. T., Auret S. Machine learning applications in minerals processing: A review. *Minerals Engineering*. 2019. Vol. 132. P. 95–109. DOI: <https://doi.org/10.1016/j.mineng.2018.12.004>
7. Chaedir B. A., Kurnia J. C., Sasmito A. P., Mujumdar A. S. Advances in dewatering and drying in mineral processing. *Drying Technology*. 2021. Vol. 39, no. 11. P. 1667–1684. DOI: <https://doi.org/10.1080/07373937.2021.1907754>
8. Araujo Jr. A. M., França S. C. A., Tavares L. M. Influence of process variables on the ceramic capillary filtration of iron ore slurries. *Minerals Engineering*. 2022. Vol. 182. Article 107562. DOI: <https://doi.org/10.1016/j.mineng.2022.107562>
9. Zhang H., Wang F., He D., Zhao L. A two-step coordinated optimization model for a dewatering process. *Canadian Journal of Chemical Engineering*. 2021. Vol. 99. P. 742–754. DOI: <https://doi.org/10.1002/cjce.23886>
10. Олійник Т. А. Перспективи розвитку технологій збагачення залізних руд. Збагачення корисних копалин : Наук.-техн. зб. 2018. Вип. 69(110). С. 32–44.
11. Oliinyk T., Sklyar L., Kushniruk N., Holiver N., Tora B. Ocena skuteczności technologii wzbogacania kwarcytu hematytowego. *Inżynieria Mineralna*. 2023. Z. 1(51). S. 33–44. DOI: <http://doi.org/10.29227/IM-2023-01-04>
12. Zhang J., Guo Y., Zheng F., Wang S., Chen F., Yang L. High efficiency filtration and optimization of pelletizing performance of fine hematite concentrate using sulfuric acid filter aid: Behavior and mechanism. *Powder Technology*. 2024. Vol. 448. Article 120260. DOI: <https://doi.org/10.1016/j.powtec.2024.120260>
13. Kang Z., Cui B., Shen Y., Zhao Q., Du H., Zhang Y. Ultrafine hematite flocculation: In-depth analysis of multi-factor and multi-index coordinated optimisation. *Process Safety and Environmental Protection*. 2025. Vol. 198. Article 107211. DOI: <https://doi.org/10.1016/j.psep.2025.107211>
14. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, CA, USA, 2016. P. 785–794. DOI: <https://doi.org/10.1145/2939672.2939785>
15. Friedman J. H. Greedy function approximation: A gradient boosting machine. *Annals of Statistics*. 2001. Vol. 29, no. 5. P. 1189–1232. DOI: <https://doi.org/10.1214/aos/1013203451>
16. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. New York : Springer, 2009. 745 p. DOI: <https://doi.org/10.1007/978-0-387-84858-7>
17. Breiman L. Random forests. *Machine Learning*. 2001. Vol. 45, no. 1. P. 5–32. DOI: <https://doi.org/10.1023/A:1010933404324>
18. Probst P., Boulesteix A., Bischl B. Tunability: Importance of hyperparameters of machine learning algorithms. *Journal of Machine Learning Research*. 2019. Vol. 20, no. 53. P. 1–32. URL: <https://jmlr.org/papers/v20/18-444.html> (дата звернення: 23.12.2024).
19. Pedregosa F., Varoquaux G., Gramfort A. [et al.] Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830. URL: <https://jmlr.org/papers/v12/pedregosa11a.html> (дата звернення: 23.12.2024).
20. Lundberg S. M., Lee S. I. A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*. 2017. Vol. 30. P. 4765–4774. URL: <https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html> (дата звернення: 23.12.2024).

REFERENCES:

1. Muwanguzi, A. J. B., Karasev, A. V., & Jönsson, P. G. (2012). Characterization of chemical composition and microstructure of natural iron ore from Muko deposits. *ISIJ International*, 52(9), 1607–1612. <https://doi.org/10.5402/2012/174803>

2. Biletskyi, V. S., Oliinyk, T. A., Smyrnov, V. O., & Skliar, L. V. (2019). Tekhnika ta tekhnolohiia zbahachennia korysnykh kopalyn. Chastyna 3. Zakliuchni protsesy [Equipment and technology of mineral processing. Part 3. Final processes]. Vydavets FOP Cherniavskiyi D. O. [in Ukrainian]
3. Mamghaderi, H., Aghababaei, S., Gharabaghi, M., Noaparast, M., Albijanic, B., & Rezaei, A. (2021). Investigation on the effects of chemical pretreatment on the iron ore tailing dewatering. *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, 625, Article 126855. <https://doi.org/10.1016/j.colsurfa.2021.126855>
4. Sohn, H. Y., & Roy, S. (2022). Development of a Moving-Bed Ironmaking Process for Direct Gaseous Reduction of Iron Ore Concentrate. *Metals*, 12(11), Article 1889. <https://doi.org/10.3390/met12111889>
5. Liu, H., & You, K. (2022). Optimization of dewatering process of concentrate pressure filtering by support vector regression. *Scientific Reports*, 12, Article 7135. <https://doi.org/10.1038/s41598-022-11259-9>
6. McCoy, J. T., & Auret, S. (2019). Machine learning applications in minerals processing: A review. *Minerals Engineering*, 132, 95–109. <https://doi.org/10.1016/j.mineng.2018.12.004>
7. Chaedir, B. A., Kurnia, J. C., Sasmito, A. P., & Mujumdar, A. S. (2021). Advances in dewatering and drying in mineral processing. *Drying Technology*, 39(11), 1667–1684. <https://doi.org/10.1080/07373937.2021.1907754>
8. Araujo Jr., A. M., França, S. C. A., & Tavares, L. M. (2022). Influence of process variables on the ceramic capillary filtration of iron ore slurries. *Minerals Engineering*, 182, Article 107562. <https://doi.org/10.1016/j.mineng.2022.107562>
9. Zhang, H., Wang, F., He, D., & Zhao, L. (2021). A two-step coordinated optimization model for a dewatering process. *Canadian Journal of Chemical Engineering*, 99, 742–754. <https://doi.org/10.1002/cjce.23886>
10. Oliinyk, T. A. (2018). Perspektyvy rozvytku tekhnolohii zbahachennia zaliznykh rud [Prospects for the development of iron ore enrichment technologies]. *Zbahachennia korysnykh kopalyn – Mineral Processing*, 69(110), 32–44. [in Ukrainian]
11. Oliinyk, T., Sklyar, L., Kushniruk, N., Holiver, N., & Tora, B. (2023). Ocena skuteczności technologii wzbogacania kwarcytu hematytowego [Evaluation of the effectiveness of hematite quartzite enrichment technology]. *Inżynieria Mineralna – Mineral Engineering*, 1(51), 33–44. <https://doi.org/10.29227/IM-2023-01-04> [in Polish]
12. Zhang, J., Guo, Y., Zheng, F., Wang, S., Chen, F., & Yang, L. (2024). High efficiency filtration and optimization of pelletizing performance of fine hematite concentrate using sulfuric acid filter aid: Behavior and mechanism. *Powder Technology*, 448, Article 120260. <https://doi.org/10.1016/j.powtec.2024.120260>
13. Kang, Z., Cui, B., Shen, Y., Zhao, Q., Du, H., & Zhang, Y. (2025). Ultrafine hematite flocculation: In-depth analysis of multi-factor and multi-index coordinated optimisation. *Process Safety and Environmental Protection*, 198, Article 107211. <https://doi.org/10.1016/j.psep.2025.107211>
14. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>
15. Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
16. Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-84858-7>
17. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
18. Probst, P., Boulesteix, A., & Bischl, B. (2019). Tunability: Importance of hyperparameters of machine learning algorithms. *Journal of Machine Learning Research*, 20(53), 1–32. Retrieved from <https://jmlr.org/papers/v20/18-444.html>
19. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830. Retrieved from <https://jmlr.org/papers/v12/pedregosa11a.html>
20. Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774. Retrieved from <https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html>



Стаття поширюється на умовах ліцензії відкритого доступу CC BY 4.0

Дата першого надходження статті до видання: 24.12.2025
 Дата прийняття статті до друку після рецензування: 13.01.2026
 Дата публікації (оприлюднення) статті: 16.03.2026