

УДК 004.942

DOI: 10.15587/2312-8372.2019.176121

РОЗРОБКА МОДЕЛІ КЛАСИФІКАЦІЇ НА ОСНОВІ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОЦЕСУ ЗБАГАЧЕННЯ ЗАЛІЗНОЇ РУДИ

Сенько А. О., Купін А. І., Мисько Б. С.

1. Вступ

В сучасних умовах особливого значення набуває завдання підвищення якості кінцевої продукції – концентрату – і зниження його собівартості, оскільки середня якість продукції гірничо-збагачувальних комбінатів (ГЗК), що становить 64–66 %, нижче ніж у потенційних конкурентів (Росія, Швеція, Бразилія) – 70 % [1]. При цьому собівартість і частка шкідливих домішок в концентратах українського виробництва, як правило, більше.

Відхилення якості концентрату від планових показників знаходиться в діапазоні $-3...+2$ %. Серед причин таких коливань в роботі першими визначені наступні: зміна мінерального складу руди, що переробляється, зміна режимів роботи технологічного обладнання дробильного відділення. Особливе значення завданню стабілізації якісних параметрів руди, що надходить на збагачення, надають складні гірничо-геологічні умови українських гірничо-збагачувальних комбінатів, що характеризуються різноманітністю мінеральних різновидів руд і значним розмахом змісту корисного компонента в них [2]. У руді, що надходить на збагачення, середня кількість мінеральних різновидів становить 5–8, а розмах змісту загального і магнітного заліза, наприклад, в умовах ВАТ «Південний ГЗК» (м. Кривий Ріг, Україна), досягає відповідно 6 % і 10 %. При цьому, сучасна система ведення гірських робіт не дозволяє досить тривалий час добувати однотипні руди, що призводить до нестабільності мінерального складу сировини, що надходить на збагачення. Протягом робочої зміни розмах змісту корисного компонента у вихідній руді сягає в середньому 7–9 абс. %.

Однією з ключових характеристик, що визначають режим роботи подрібнюючого апарату являється подрібнюваність руди, прямо пов'язана з її міцністю [3]. Але на відміну від інших параметрів є проблема із постійним відстеженням значення міцності. Визначення даного параметру потребує лабораторного дослідження технологічної проби руди з конвеєра секції збагачення. Зміна показників у період між заборами проб негативно впливає на подальше керування технологічним процесом через неадекватність вхідних даних.

Тому актуальним є дослідження альтернативних методів визначення міцності руди. Зокрема, прогнозування даного параметру із застосуванням моделі класифікації для процесу збагачення.

2. Об'єкт дослідження та його технологічний аудит

Об'єктом дослідження є процеси збагачення залізородної сировини в умовах гірничо-збагачувального комбінату.

Фабрика по збагаченню залізних руд є рядом паралельно діючих технологічних ліній або секцій збагачення. Технологічну лінію магнітного збагачення руд можна умовно розділити на ряд послідовно з'єднаних технологічних комплексів, кожен з яких включає в себе технологічні операції: подрібнення, класифікацію та магнітну сепарацію. Подрібнення руди може здійснюватися в кульових і безкульових млинах.

Специфіка умов роботи секції збагачення ускладнює відстеження параметру міцності шляхом встановлення апаратного датчика безпосередньо на конвеєрі. Тому було запропоновано визначати її шляхом прогнозування. Спираючись на інформаційні технології Big Data, використовуючи накопичені статистичні дані можна робити прогноз даних на проміжках між технологічними пробами.

3. Мета та задачі дослідження

Мета дослідження – створення класифікуючої моделі непрямого визначення вхідних параметрів роботи секції збагачення із застосуванням інтелектуальної технології прийняття рішень. Це дозволить підвищити ефективність технологічного процесу збагачення залізної руди.

Для досягнення поставленої мети необхідно виконати такі задачі:

1. Сформулювати загальну мету побудови класифікуючої моделі непрямого визначення вхідних параметрів роботи секції збагачення.
2. Розкрити окремі блоки та загальні концепції функціонування пропонованої моделі.
3. Надати формалізований опис зв'язків між окремими елементами моделі.

4. Дослідження існуючих рішень проблеми

Виробничий процес переробки мінералів – типовий складний промисловий процес. Він складається з декількох процесів, з'єднаних послідовно, де виходи кожного окремого процесу є входами для наступного [4].

Функціонування кожного блоку містить систему оперативної оптимізації вищого рівня, що утримує показники експлуатації в межах цільових діапазонів [5, 6].

Використання оптичних камер з роздільною здатністю до 0,1 мм для визначення властивостей сировини потребує їх попереднього очищення [7].

Рентгенорадіометричні методи контролю якості кускової руди в числі недоліків мають недостатню глибину проникнення випромінювання [2].

Основне обмеження систем на основі рентгенівської флуоресценції полягає в тому, що вони не в змозі кількісно оцінити елементи, що випромінюють світло [8].

Інфрачервона термографія не дозволяє працювати з чорними матеріалами, що погано відбивають інфрачервоне випромінювання [9].

Частинки сировини, що мають низький вміст металу не можуть бути виявлені електромагнітними датчиками [10]. Для виявлення такої сировини необхідно встановити додаткові вимірювальні прилади.

Ультразвукові датчики [11] дозволяють виявити до п'яти класів розміру сировини у суспензіях, що на 60 % складаються з твердих тіл.

Крім аналізу потоку сировини доступний цілий спектр методів, що вимагають систематичного або автоматичного відбору зразків [12]. Їх недоліком являється велика затримка у часі (від кількох годин до кількох діб).

Розглянуті вище методи не дозволяють отримувати інформацію про сировину, що надходить до секції збагачення, для оперативного керування технологічним процесом. Пропонується розробити модель, що дозволить прогнозувати невідомі дані на основі попередньо накопиченої статистики.

5. Методи дослідження

При дослідженні були використані наступні наукові методи:

- метод аналізу – при вивченні проблематики питання та постановки окремих завдань дослідження;
- метод узагальнення, абстрагування та пояснення – для розкриття класифікуючої моделі та взаємозв'язків між окремими її блоками;
- метод математичного аналізу та оптимізації – для визначення аналітичної формалізації й опису класифікуючої моделі.

6. Результати дослідження

Продуктивність кульових млинів залежить від багатьох факторів. Автором роботи [13] введено три ряди факторів. Перший ряд створюється факторами, які визначаються матеріалом, що подрібнюється: крупність вихідної руди, крупність подрібненого матеріалу, подрібнюваність руди. Другий ряд містить фактори, що залежать від самого млина: конструкція кульового млина, його розміри, форма футеровки. Третій ряд подано факторами, що враховують умови експлуатації технологічного агрегату:

- відкритий або замкнутий цикл;
- ефективність роботи класифікуючого апарата;
- ступінь заповнення млина подрібнюючим середовищем;
- характеристика крупності;
- форма;
- густина;
- твердість подрібнюючих тіл;
- розрідження пульпи у млині;
- число обертів барабана.

В процесі системного дослідження кульового млина як керованого об'єкта по каналу продуктивності отримана його модель, як керованого об'єкта (рис. 1).

Аналіз факторів, поданих на рис. 1, показує, що їх можливо представити у вигляді параметрів процесу, що оптимізується. При цьому звичайно за змістом виділяють вхідні, вихідні, збурюючі та керуючі параметри.

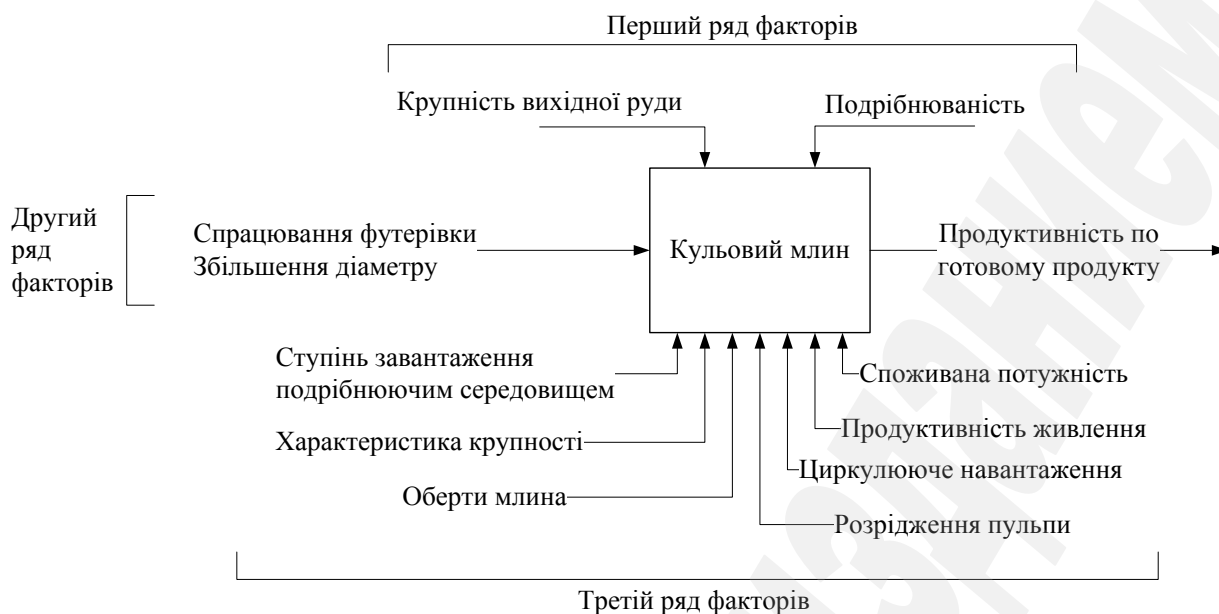


Рис. 1. Модель кульового млина як керованого об'єкта

Техніко-мінералогічні різновиди руд Північного ГЗК за показником міцності за шкалою проф. М.М. Протод'яконова змінюються в основному в межах 6–9 балів. Загальна тенденція зменшення міцності зразків при збільшенні їх розміру пояснюється наявністю в них великих і дрібних тріщин, кількість яких зі зменшенням крупності зразків зменшується.

Виходячи з описаного технологічного процесу загальну структуру прогнозуючої моделі можна поділити на декілька блоків (рис. 2).

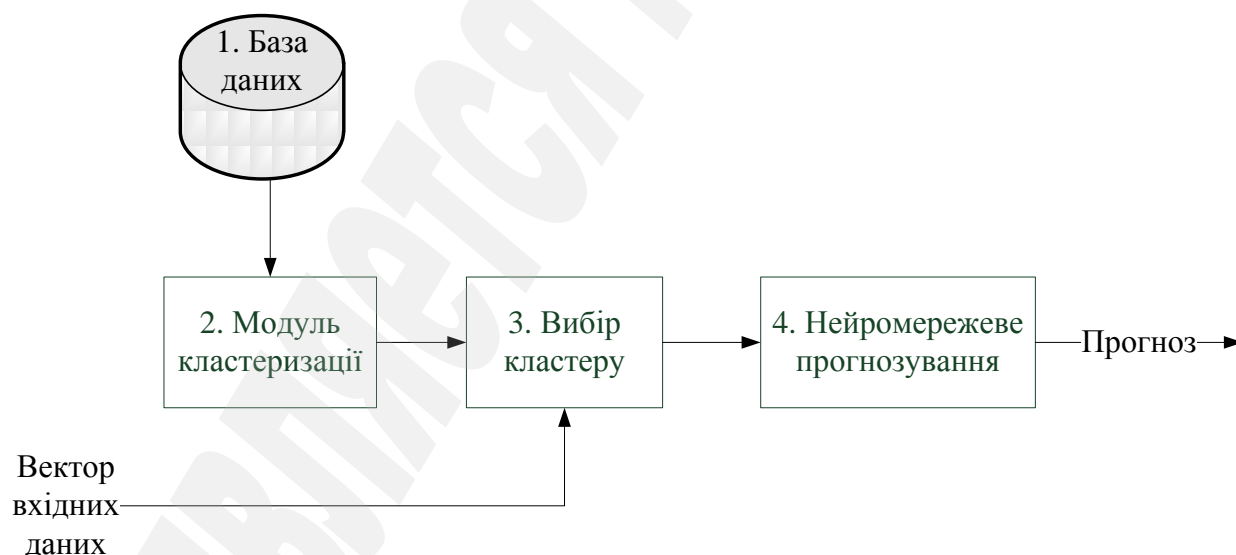


Рис. 2. Загальна структура прогнозуючої моделі

Перший блок представляє собою базу даних (БД), що містить накопичені дані статистики роботи секції збагачення за попередній період експлуатації. Показники отримані від встановлених датчиків контролю роботи секції та лабораторних даних аналізу сировини та продуктів роботи секції.

Призначенням системи управління технологічної бази даних є накопичення, резервування та зберігання інформації про динаміку параметрів технологічного процесу [10]. Для реалізації в результаті аналізу альтернативних варіантів (Oracle, Firebird, Interbase, Sybase Adaptive Server Enterprise, MySQL) була обрана промислова система управління базами даних (СУБД) MS SQL Server.

Модуль кластеризації. Формально задача кластеризації статистичних даних секції збагачення може бути описана наступним чином. Дано множину об'єктів даних I (статистика станів роботи секції), кожен з яких характеризується набором атрибутів. Необхідно побудувати множину кластерів C і відображення F множини I на множину C , тобто $F:I \rightarrow C$. Відображення F задає модель даних, що являються рішенням задачі. Множина I визначається наступним чином:

$$I = \{i_1, i_2, \dots, i_n\},$$

де ij – досліджуваний об'єкт.

Кожен з об'єктів характеризується набором параметрів:

$$ij = \{x_a, x_s, x_d, x_i\}.$$

Кожна змінна x_k ($i = \{a, s, d, i\}$) може приймати значення з деякої множини:

$$x_k = \{v_{k1}, v_{k2}, \dots\}.$$

Задача кластеризації полягає в побудові множини:

$$C = \{c_1, c_2, \dots, c_k, \dots, c_g\},$$

де c_k – кластер, що містить «схожі» один з одним об'єкти із множини I :

$$c_k = \{ij, ik \mid ij \in I, ik \in I \text{ та } d(ij, ik) < \sigma\};$$

де σ – величина, що визначає міру близькості для включення об'єктів в один кластер; $d(ij, ik)$ – міра близькості між об'єктами, що зветься відстанню.

Невід'ємне значення $d(ij, ik)$ називається відстанню між елементами ij та ik , якщо виконуються наступні умови:

- 1) $d(ij, ik) \geq 0$, для всіх ij та ik ;
- 2) $d(ij, ik) = 0$, тоді і тільки тоді, коли $ij = ik$;
- 3) $d(ij, ik) = d(ik, ij)$;
- 4) $d(ij, ik) \leq d(ik, im) + d(im, ik)$.

Якщо відстань $d(ik, ik)$ менша за деяке σ , то говорять, що елементи близькі і переміщуються до одного кластеру. В іншому випадку вважається, що елементи відрізняються один від одного і їх переміщують в різні кластери. Відстані між

об'єктами припускають їх представлення у вигляді точок m багатовимірному простору Rm (в означеному випадку $m=4$). В якості міри може бути використано Евклідову відстань. Цю відстань обчислюють наступним чином:

$$d(ij, ik) = \sqrt{\sum_{t=1}^m (x_{jt} - x_{kt})^2}. \quad (1)$$

Щоб надати більшої ваги більш віддаленим один від одного об'єктам, стандартна Евклідова відстань підноситься до квадрату.

Для вирішення поставленого завдання кластеризації використано пакет Microsoft Analysis Services, що є частиною системи управління базами даних Microsoft SQL Server. А також, що дозволяє зберігати дані і виконувати бізнес аналіз за рахунок коштів роботи з OLAP (OnLine Analytical Processing) і інтелектуальним аналізом даних. У пакеті реалізований метод Microsoft Clustering, що базується на двох принципових алгоритмах кластеризації: алгоритм k -середніх (K-Means) і EM-алгоритм (Expectation Maximization). Обидва алгоритми відносяться до класу так званих неієрархічних алгоритмів, заснованих на оптимізації деякої цільової функції, яка визначає оптимальне розбиття множини даних на групи. Перший метод, алгоритм k -середніх – метод жорсткої кластеризації. Це означає, що точка даних може належати тільки одному кластеру і для приналежності кожної точки даних цього кластеру обчислюється одне значення ймовірності. Другий метод, максимізація очікувань (EM) – це метод м'якої кластеризації. Це означає, що точка даних завжди належить до кількох кластерів і для всіх можливих поєднань точок даних з кластерами обчислюються ймовірності.

Третій блок обирає з отриманих на попередньому етапі кластерів набір даних, що буде використовуватись для навчання нейронної мережі. В якості критерію вибору використовується приналежність вектору вхідних параметрів модуля одному з отриманих кластерів. Мінімальна відстань до центру кластеру за формулою (1) визначає дану приналежність.

У четвертому блоці відбувається прогнозування невідомого параметру стану секції збагачення. Спочатку проходить навчання нейронної мережі. В якості вибірки для навчання використовуються дані статистики роботи секції збагачення обраного на попередньому етапі кластеру. Після навчання на вхід нейронної мережі подаються параметри поточного стану роботи секції збагачення. У результаті прогнозування на виході мережі буде отримано значення невідомого параметру роботи секції збагачення.

В рамках дослідження найбільшу перспективу мають нейромережі зустрічного розповсюдження (рис. 3). Мережі цього типу мають менший час навчання, ніж мережі зворотнього розповсюдження. Тому така мережа оперативно відреагує на зміну умов процесу збагачення, пов'язану із флуктаціями характеристик вхідної сировини. У нейромережі зустрічного розповсюдження об'єднані такі алгоритми: самоорганізуюча карта Кохонена та

зірка Гроссберга. Їх об'єднання призводить до зростання узагальнюючих властивостей мережі [14].

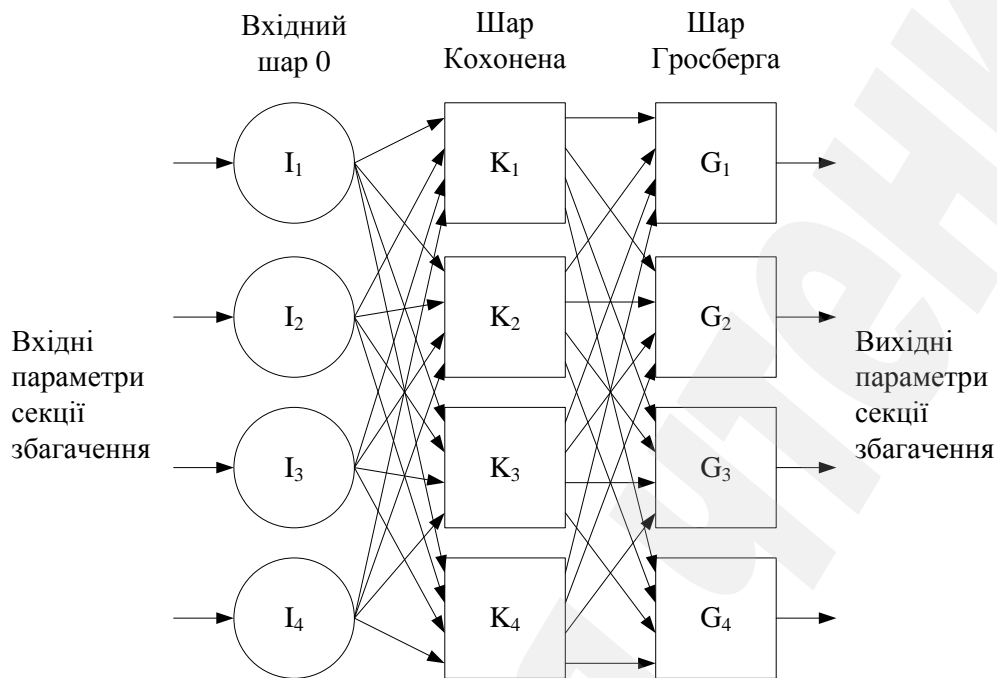


Рис. 3. Мережа із зустрічним розпізнаванням без зворотних зв'язків

Створена модель представлена стандартною трьохшаровою (0–2) нейромережею зустрічного розповсюдження. Нейрони шару 0 слугують точками розгалуження і не приймають участі в обчисленнях. Кожен нейрон шару 0 пов'язаний з кожним нейроном шару 1 (шар Кохонена). Аналогічно пов'язані нейрони шару 1 і 2. Вихід кожного нейрона шару являється сумою зважених входів. В результаті порівняльного оцінювання зважених сум входів нейронів Кохонена визначається «переможець» – нейрон, для якого це значення максимальне. Виходу цього нейрона буде присвоєно значення 1, а іншим нейронам шару Кохонена – 0. Шар Кохонена класифікує вхідні вектори в подібні групи [15]. Тим самим забезпечується відображення багатомірного простору входів в окіл однієї і тієї ж точки простору виходів.

Нейрон в формі вхідної зірки має n входів, яким відповідають вагові коефіцієнти $W=(w_1, w_2, \dots, w_n)$, один вихід Y , що є зваженою сумою цих входів. Таким чином, зірка є детектором стану входів і реагує тільки на свій вхідний вектор.

Підстроювання ваг здійснюється за формулою:

$$W_i(t+1) = W_i(t) + \mu \cdot (X_i - W_i(t)), \quad (2)$$

де $W_i(t)$ – ваговий вектор i -ої вхідної зірки на t -м такті навчання;

μ – швидкість навчання (вибирається на початку 0,1–0,2 і потім поступово зменшується);

X_i – вхідний вектор.

Вихідна зірка Гроссберга виконує протилежну функцію – при надходженні сигналу на вхід видається певний вектор. Нейрон цього типу має один вхід і m виходів з вагами $W=(w_1, w_2, \dots, w_n)$, які підлаштовуються по формулі:

$$W_i(t+1) = W_i(t) + \alpha' \cdot (Y_i - W_i(t)), \quad (3)$$

де $W_i(t)$ – ваговий вектор i -ої вихідної зірки на t -м такті навчання;

Y_i – вихідний вектор;

α' – швидкість навчання. Рекомендується почати навчання з $\alpha' = 1$ і поступово зменшувати до 0.

Використання нейромережевої моделі передбачає апріорну класифікацію станів системи (процесу збагачення) на скінченне число варіантів [16, 17]. З кожним станом пов'язаний набір корегуючих впливів, що передбачають конкретні зміни керуючих параметрів. В якості основного критерію класифікації використовується значення вихідних векторів Y . Для визначення поточного стану процесу проводиться порівняння виходу нейромережевої моделі та збережених в інформаційній базі систем векторів, що визначають стан процесу збагачення.

7. SWOT-аналіз результатів досліджень

Strengths. Розроблено концептуальну комплексну класифікуючу модель непрямого визначення вхідних параметрів роботи секції збагачення. Визначено та розкрито взаємозв'язки між окремими елементами побудованої моделі. Це дозволяє більш оперативно визначати характеристики сировини, що подається на вхід секції збагачення та, реагуючи на їх зміни, обрати оптимальні режими роботи секції.

У порівнянні з аналогічними розробками, це дозволяє отримувати дані про вхідну сировину без розміщення додаткових високовартісних датчиків на вхідному конвеєрі секції.

Weaknesses. Слабкою стороною можна вважати те, що для навчання нейронна мережа потребує накопичення певного обсягу статистичних даних роботи секції збагачення. Це ускладнює застосування даної моделі для нового обладнання.

Opportunities. Застосування системи комп'ютерної підтримки рішень на базі запропонованої моделі може підвищити оперативність отримання даних про вхідну сировину до 24 разів.

Threats. При появі збагачувальних комплексів, що включають вимірювальне обладнання для визначення характеристик сировини на вході секції збагачення, зникає необхідність у застосуванні запропонованої моделі.

8. Висновки

1. Показано, що основною метою класифікуючої моделі непрямого визначення вхідних параметрів роботи секції збагачення є отримання даних про вхідну сировину на основі інформації про поточний стан роботи секції збагачення. Це зроблено на підставі проведеного узагальнюючого аналізу з висвітлення

пропонованої проблематики питання в аналогічних існуючих дослідженнях та з врахуванням сформульованої загальної мети побудови такої моделі.

2. Задля досягнення основної мети побудови класифікуючої моделі визначено та розкрито основні блоки її побудови, зокрема:

- «База даних»;
- «Модуль кластеризації»;
- «Вибір кластеру»;
- «Нейромережеве прогнозування».

3. Запропоновано формалізований опис зв'язків між окремими елементами моделі. Комбінація методів кластеризації зменшує навантаження на апаратну частину, оскільки метод масштабованої максимізації очікування використовує локальний буфер. А ітерації з переглядом всіх даних працюють швидше і цей алгоритм набагато краще використовує кеш-пам'ять процесора, ніж метод немасштабованої максимізації очікування. Представлений алгоритм прогнозування, заснований на поєднанні методів кластеризації та використанні прогнозуючої нейромережі, дає можливість фахівцеві більш оперативно отримати рекомендації щодо прийняття рішень відносно поведінки об'єкту у порівнянні із отриманням даних лабораторного дослідження проби.

Література

1. Купін, А. І. (2009). *Узгоджене інтелектуальне керування стадіями технологічного процесу збагачення магнетитових кварцитів в умовах невизначеності*. Кривий Ріг: Криворізький національний університет, 926.

2. Гончаров, Ю. Г., Давидкович, Ю. Г., Гейзенблазен, Б. Е. (1968). *Автоматический контроль и регулирование технологических процессов на железорудных обогатительных фабриках*. Москва: Недра, 277.

3. Скороходов, В. Ф., Хогуля, М. С., Бирюков, В. В. (2010). Создание эффективных технологий и техники обогащения минерального сырья с применением методов вычислительной гидродинамики. *Горный журнал*, 12, 79–84.

4. Ding, J., Chai, T., Wang, H. (2011). Offline Modeling for Product Quality Prediction of Mineral Processing Using Modeling Error PDF Shaping and Entropy Minimization. *IEEE Transactions on Neural Networks*, 22 (3), 408–419. doi: <https://doi.org/10.1109/tnn.2010.2102362>

5. Jäschke, J., Skogestad, S. (2011). NCO tracking and self-optimizing control in the context of real-time optimization. *Journal of Process Control*, 21 (10), 1407–1416. doi: <https://doi.org/10.1016/j.jprocont.2011.07.001>

6. Würth, L., Hannemann, R., Marquardt, W. (2011). A two-layer architecture for economically optimal process control and operation. *Journal of Process Control*, 21 (3), 311–321. doi: <https://doi.org/10.1016/j.jprocont.2010.12.008>

7. Lu, L. (2015). *Iron Ore. Mineralogy, Processing and Environmental Sustainability*. Elsevier, 666. doi: <https://doi.org/10.1016/c2013-0-16476-8>

8. Wills, B. A., Napier-Munn, T. (2006). *Wills' Mineral Processing Technology*. Elsevier, 456. doi: <https://doi.org/10.1016/b978-0-7506-4450-1.x5000-0>

9. Ghosh, A., Sharma, A. K., Nayak, B., Sagar, S. P. (2014). Infrared thermography: An approach for iron ore gradation. *Minerals Engineering*, 62, 85–90. doi: <https://doi.org/10.1016/j.mineng.2013.12.002>
10. Неведров, А. С., Олейник, А. Г. (2011). Об инструментальных средствах определения эффективных режимов обогащения минеральных руд. *Информационные ресурсы России*, 5, 35–38.
11. Morkun, V., Tron, V. (2014). Automation of iron ore raw materials beneficiation with the operational recognition of its varieties in process streams. *Metallurgical and Mining Industry*, 6, 4–7.
12. Hart, J. R., Zhu, Y., Pirard, E. (2011). Particle size and shape characterization: current technology and practice. *Advances in the Characterization of Industrial Minerals*, 77–127. doi: <https://doi.org/10.1180/emu-notes.2010.emu9-4>
13. Андреев, С. Е., Перов, В. А., Зверевич, В. В. (1980). *Дробление, измельчение и грохочение полезных ископаемых*. Москва: Недра, 415.
14. Werbos, P. J. (1989). Backpropagation and neurocontrol: a review and prospectus. *International Joint Conference on Neural Networks*. doi: <https://doi.org/10.1109/ijcnn.1989.118583>
15. Haykin, S. (1994). *Neural Networks. A comprehensive foundation*. New York: Macmillan, 696.
16. Zhang, B., Muhlenbein, H. (1993). Evolving optimal neural networks using genetic algorithms with Occam's razor. *Complex systems*, 7 (3), 199–220.
17. Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Massachusetts, 432.