

УДК 004.032.26:622.73

*Аблець А.В., аспірант,
Тронь В.В., к.т.н., доцент
Криворізький національний університет*

ГІБРИДНА ФІЗИЧНО-ІНФОРМОВАНА НЕЙРОМЕРЕЖА ДЛЯ ПРОГНОЗУ СПОЖИВАНОЇ ПОТУЖНОСТІ МЛИНА НАПІВСАМОПОДРІБНЕННЯ НА ГОДИНУ ВПЕРЕД

Млин напівсамоподрібнення (SAG-млин) є одним із найбільших споживачів електроенергії на збагачувальній фабриці. Тому прогноз його споживаної потужності на годину вперед має цілком прикладне значення: він дає змогу коригувати режим роботи, вирівнювати енергетичне навантаження та раніше виявляти відхилення в процесі.

Підходи до такого прогнозування помітно різняться. Фізичні моделі добре відображають закономірності процесу, але потребують параметрів, яких у SCADA-архівах часто немає або які оцінюються з великою невизначеністю [1]. Моделі, що спираються лише на дані, зазвичай дають меншу похибку, проте їх важче інтерпретувати, а при зміні технологічного режиму вони не завжди залишаються достатньо стійкими [2].

У роботі розглянуто гібридну модель Elastic Physics-Informed Neural Network (Elastic-PINN), у якій нейромережева частина поєднується з фізичним регуляризатором [3, 4]. Термін «elastic» означає, що фізичне обмеження вводиться м'яко через зважений компонент функції втрат, а коефіцієнти фізичної моделі адаптуються під час навчання. Фізична гілка не замінює основний прогнозувач, а лише стримує модель від фізично неправдоподібних рішень.

Спираючись на відому залежність потужності від швидкості обертання [1], у фізичній гілці використано спрощену апроксимацію:

$$P = kS^n + aF + b_0$$

Тут S - частота обертання млина, F - витрата руди; коефіцієнти k , n , a та b_0 спершу оцінюються методом найменших квадратів, а далі оптимізуються разом із параметрами мережі. Абляційний аналіз показав, що саме коефіцієнти, що навчаються, дають найбільший внесок у підсумкову точність моделі.

Нейромережеву складову реалізовано на основі Temporal Convolutional Network (TCN) із каузальними розширеними згортками [5]. Окремий LSTM-модуль прогнозує частоту обертання та витрату руди на горизонті 60 хвилин. У підсумку модель враховує часову динаміку процесу і водночас зберігає фізичну інтерпретованість.

Модель оцінено на промисловому масиві SCADA-даних тривалістю 117 діб із дискретністю 1 хвилина. У нормальному режимі роботи отримано $RMSE = 0,633$ МВт та $MAE = 0,490$ МВт, що відповідає приблизно 4,7 % від середньої тестової потужності 13,56 МВт. Перевага над найкращою моделлю без фізичної складової невелика, але простежується стабільно.

Абляційний аналіз дав змогу з'ясувати, за рахунок чого саме працює модель. Фіксація коефіцієнтів, оцінених методом найменших квадратів, погіршує $RMSE$ на 30,2 %, а вилучення фізичного компонента з функції втрат - на 14,8 %. Якщо ж замінити прогнозовані екзогенні змінні їхніми істинними майбутніми значеннями, похибка зменшується ще приблизно на 13 %. Це свідчить, що головне обмеження точності пов'язане насамперед із прогнозом екзогенних змінних, а не з архітектурою моделі потужності.

Загалом гібридна архітектура поєднує прийнятну точність короткострокового прогнозування з інтерпретованістю. Наукова новизна полягає у поєднанні коефіцієнтів фізичної моделі, що навчаються, з м'якою регуляризацією в архітектурі PINN для прогнозування потужності SAG-млина з урахуванням прогнозу екзогенних змінних. Навчувані фізичні коефіцієнти можна аналізувати окремо, а сам підхід придатний для подальшого використання в системах підтримки прийняття рішень на збагачувальній фабриці.

Список використаних джерел:

1. Silva M., Casali A. Modelling SAG milling power and specific energy consumption including the feed percentage of intermediate size particles // Minerals Engineering. 2015. Vol. 70. P. 156-161.
2. Zhang D., Xiong X., Shao C., Zeng Y., Ma J. Semi-autogenous mill power consumption prediction based on CACN-LSTM // Applied Sciences. 2025. Vol. 15, No. 1. Article 2.
3. Karniadakis G. E., Kevrekidis I. G., Lu L., Perdikaris P., Wang S., Yang L. Physics-informed machine learning // Nature Reviews Physics. 2021. Vol. 3. P. 422-440.
4. Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. 2019. Vol. 378. P. 686-707.
5. Bai S., Koltner J. Z., Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling // arXiv. 2018. URL: <https://arxiv.org/abs/1803.01271> (дата звернення: 10.01.2026).