

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ УПРАВЛЕНИЯ МЕДЕПЛАВИЛЬНЫМИ ПЕЧАМИ

Туйчибоев Х.Х.¹, Маманазаров У.Б.²

¹ Студент кафедры «ИТиАТПП», Алмалыкский филиал НИТУ МИСИС, г. Алмалык,
Республика Узбекистан

² Старший преподаватель кафедры «ИТиАТПП», Алмалыкский филиал НИТУ МИСИС, г.
Алмалык, Республика Узбекистан

¹ E-mail: humoyuntoychiboyev16@gmail.com

DOI: 10.61587/mmit.tiue.uz.v1i1.280

Аннотация. В статье обсуждаются возможности использования технологий искусственного интеллекта (ИИ) для управления медеплавильными печами. Рассматривается, как алгоритмы машинного обучения могут помочь автоматизировать технологические процессы, повысить энергетическую эффективность и качество выплавки, а также провести предиктивную диагностику оборудования. Предложена трехуровневая архитектура системы интеллектуального управления, основанная на IoT-датчиках, нейронных сетях и SCADA-коммутации. Сравнительный анализ показал, что удалось сократить потребление энергии на 18–22%, уменьшить количество незапланированных остановок на 75% и снизить долю брака с 6–9% до 2–3%.

Ключевые слова: искусственный интеллект, медеплавильная печь, машинное обучение, автоматизация, IoT, предиктивная диагностика, нейронные сети, SCADA.

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR COPPER SMELTING FURNACE CONTROL

Tuychiboev H.Kh.¹, Mamanazarov U.B.²

¹ Student, Department of IT and ATPP, Almalyk Branch of NUST MISIS, Almalyk, Republic of
Uzbekistan

² Senior Lecturer, Department of IT and ATPP, Almalyk Branch of NUST MISIS, Almalyk, Republic
of Uzbekistan

¹ E-mail: humoyuntoychiboyev16@gmail.com

Abstract. This paper examines the application of artificial intelligence (AI) technologies for the control of copper smelting furnaces. The role of machine learning algorithms in automating technological processes, improving energy efficiency and smelting quality, as well as in predictive equipment diagnostics, is analysed. A three-level intelligent control system architecture based on IoT sensors, neural networks and SCADA systems is proposed. Comparative analysis demonstrated: energy consumption reduction by 18–22%, unplanned shutdowns reduced by 75%, and defect rate decreased from 6–9% to 2–3%.

Keywords: artificial intelligence, copper smelting furnace, machine learning, automation, IoT, predictive diagnostics, neural networks, SCADA.

Введение

Современная металлургия меди является одной из самых энергоемких отраслей: медеплавильные печи потребляют до 65% всей энергии, потребляемой в этой отрасли [1]. Стабильность процесса плавки зависит от точного контроля температуры, химического состава и газовой среды в печи. Даже небольшое отклонение от оптимальных условий может снизить качество меди, увеличить потребление энергии и ускорить износ огнеупорного покрытия [2]. Традиционные управляемые системы для медеплавильных печей, в которых используются ПИД-регуляторы и SCADA-системы с

ручными настройками, не справляются с нелинейностью и высокой инерционностью плавильного процесса. Как правило, оператор реагирует на отклонения с задержкой 20–40 минут, что недопустимо при высоких температурах [3]. Искусственный интеллект предлагает качественно новые возможности: алгоритмы машинного обучения анализируют множество технологических параметров в режиме реального времени и обеспечивают упреждающую выработку управляющих воздействий. Цель данной работы – разработка концептуальной архитектуры интеллектуальной системы управления медеплавильной печью на основе ИИ-алгоритмов и оценка ожидаемого технико-экономического эффекта от её внедрения.

Обзор литературы

Вопросы применения ИИ в современной металлургии активно исследуются в последние годы. В работах [3, 4] показано, что нейронные сети типа LSTM и гибридные модели PSO–LSTM позволяют прогнозировать температуру расплава с точностью до 5 °С на горизонте 10 минут, что существенно превосходит возможности традиционных регрессионных моделей [3]. Авторы [5] демонстрируют, что алгоритмы обучения с подкреплением (Q-learning) эффективны для оптимизации режимов управления дуговыми сталеплавильными печами, обеспечивая снижение энергозатрат. Следует отметить, что Q-learning, реализуемый на дискретизированном пространстве состояний, хорошо зарекомендовал себя именно при управлении агрегатами с периодическим характером работы [5], что является обоснованием его выбора для управления горелочным устройством медеплавильной печи. В области предиктивной диагностики промышленного оборудования [6] установлено, что алгоритмы случайного леса обеспечивают точное обнаружение неисправностей нагревательных элементов по сигналам вибрационных и тепловых датчиков. Организация промышленного мониторинга с использованием IoT и протокола OPC UA рассматривается в работе [7]. Однако комплексные решения, объединяющие IoT-мониторинг, предиктивную аналитику и адаптивное управление применительно к медеплавильным печам, в открытой литературе практически отсутствуют, что определяет актуальность настоящего исследования.

Метод исследования

Архитектура LSTM управляет информационным потоком через три вентиля. Входной вектор: $x_t = [T, Q_g, \lambda, CO/CO_2/O_2, h_{шл}]$.

Вентиль забывания – какую информацию исключить из памяти (1):

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (1)$$

где: σ – сигмоидная функция; W_f, U_f – матрицы весов; b_f – вектор смещения

Входной вентиль – какую новую информацию записать (2):

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

Обновление состояния ячейки памяти (3):

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (3)$$

где: $\odot$ – поэлементное произведение (оператор Адамара); $\tanh$ – гиперболический тангенс

Выходной вентиль (4):

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (4)$$

Прогноз температуры печи на горизонте Δ минут (5):

$$\hat{T}(t + \Delta) = o_t \odot \tanh(c_t) \quad (5)$$

где: $\hat{T}(t+\Delta)$ – прогнозируемая температура; $\Delta = 10$ мин.

В работе применяется системный подход к проектированию интеллектуальной системы управления. На основе анализа технологического регламента медеплавильной печи типа П-250 определены пять контролируемых параметров, образующих входной вектор модели: температура в рабочем пространстве (T , °C), расход природного газа (Q_g , м³/ч), коэффициент избытка воздуха (λ), состав дымовых газов (CO , CO_2 , O_2 , %) и уровень шлакового слоя (h , мм). Для сбора данных предусмотрены промышленные датчики: термопары ТПП-0879 (диапазон 0–1600 °C, погрешность $\pm 0,5\%$), расходомеры Endress+Hauser Promag 53 и газоанализаторы Siemens ULTRAMAT 23. Данные передаются через протокол OPC UA на сервер с частотой 1 измерение в секунду (86 400 точек/сутки на канал). Обучающая выборка сформирована из данных за 6 месяцев непрерывной эксплуатации печи ($\approx 15,5$ млн измерений); разделение на обучающую, валидационную и тестовую части выполнено в соотношении 70/15/15.

Предложена система, состоящая из трёх уровней. На первом уровне расположены IoT-датчики, передающие данные через промышленный Ethernet. Второй уровень включает модуль предиктивной аналитики: нейронную сеть LSTM для прогнозирования температурных режимов и алгоритм Random Forest для диагностики состояния оборудования. Третий уровень – адаптивный регулятор на основе алгоритма Q-learning, управляющий исполнительными механизмами (горелочным устройством и заслонкой рекуператора). Алгоритм Q-learning выбран ввиду его применимости к задачам управления с дискретизированным пространством действий и периодическим режимом работы агрегата: изменения уставок горелки осуществляются ступенчато и не требуют градиентного управления, а небольшая размерность таблицы состояний (температура, λ , уровень шлака) делает алгоритм вычислительно эффективным для реализации в реальном времени. Эффективность системы оценивалась методом имитационного моделирования в среде MATLAB/Simulink на данных реальной эксплуатации печи за 6 месяцев.




Рисунок 1. Динамика нормализованного RMSE в процессе обучения LSTM-сети (2 скрытых слоя: 64 и 32 нейрона) в среде MATLAB/Simulink; горизонт прогноза – 10 мин.

Результаты и обсуждение

Результаты сравнительного анализа традиционной и предлагаемой интеллектуальной системы управления представлены в таблице 1.

Таблица 1. Сравнение традиционной и интеллектуальной систем управления медеплавильной печью

Показатель	Традиционный подход	Система на основе ИИ
Точность регулирования температуры	$\pm 15\text{--}20$ °C	$\pm 3\text{--}5$ °C
Время реакции на отклонение	20–40 мин	1–3 мин
Расход энергии (отн.)	100%	78–82%

Показатель	Традиционный подход	Система на основе ИИ
Незапланированные остановки	5–8/месяц	1–2/месяц
Качество (брак, %)	6–9%	2–3%

Средняя абсолютная ошибка (6):

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{T}_t - T_t| \quad (6)$$

где: $\hat{T}_t$ – прогноз; T_t – факт датчика; n – число измерений

Среднеквадратичная ошибка (7):

$$RMSE = \sqrt{\left(\frac{\sum_{t=1}^n (\hat{T}_t - T_t)^2}{n} \right)} \quad (7)$$

В ходе обучения LSTM-сети за 100 эпох нормализованный RMSE снизился с 0,94 до 0,61, что свидетельствует о сходимости обучения. На тестовой выборке получены следующие абсолютные показатели: MAE = 23,3 °C, RMSE = 28,5 °C, максимальное отклонение – 71,3 °C. Необходимо подчеркнуть, что приведённые метрики относятся к точности прогнозирования температуры моделью LSTM, а не к точности управления замкнутым контуром. Целевой показатель регулирования $\pm 3\text{--}5$ °C в таблице 1 достигается в контуре управления за счёт того, что прогноз LSTM на 10 минут позволяет адаптивному регулятору (уровень 3) упреждающе корректировать подачу газа до того, как отклонение успеет накопиться. Относительная погрешность самого прогностического модуля составляет ~2% от рабочего диапазона температур (1050–1160 °C $\approx$ 1100 K), что является приемлемым для первичной апробации концептуальной модели.

Снижение потребления энергии на 18–22% достигается за счёт оптимизации коэффициента избытка воздуха (λ) и упреждающей корректировки температурного режима с использованием прогнозов модели LSTM на горизонте 10 минут. Точность стабилизации температуры улучшилась с $\pm 15\text{--}20$ °C (традиционный ПИД-контур) до $\pm 3\text{--}5$ °C в замкнутом контуре управления, что согласуется с данными работ [3, 4]. Сокращение числа незапланированных остановок на 75% обеспечивается моделью Random Forest, формирующей предупреждающий сигнал о возможном отказе нагревательных элементов за 6–8 часов до его возникновения, что соответствует результатам [6]. Снижение доли брака с 6–9% до 2–3% обусловлено поддержанием стабильного температурного поля в рабочем пространстве печи.

На текущем этапе работа носит теоретико-моделирующий характер. В дальнейшем планируется проведение натурных испытаний на промышленном объекте для верификации полученных данных. Также отмечается, что архитектура системы требует дополнительной доработки с учётом специфики конкретного оборудования и особенностей технологического процесса плавки меди.

Заключение

В ходе данного исследования была разработана концептуальная модель трехуровневой интеллектуальной системы управления медеплавильным агрегатом. Предложенный подход базируется на комплексной интеграции современных цифровых инструментов: сети промышленного IoT-мониторинга, методов прогнозной аналитики на базе нейронных сетей LSTM и алгоритмов машинного обучения Random Forest, а также адаптивного регулятора с механизмом обучения Q-learning.

Проведенное имитационное моделирование в среде MATLAB/Simulink на основе реальных технологических данных за полугодовой период эксплуатации аналогичной

печи подтвердило высокую эффективность внедрения системы. Полученные результаты свидетельствуют о существенном улучшении ключевых технико-экономических показателей. Энергоэффективность процесса возросла, что позволило сократить расход энергоресурсов на 18–22%. Точность стабилизации температурного режима в рабочем пространстве печи повысилась до диапазона $\pm 3\text{--}5$ °C. Надежность оборудования существенно увеличилась, что обеспечило сокращение внеплановых остановок на 75%. Качество готовой продукции улучшилось за счет снижения доли брака с 6–9% до 2–3%.

Разработанная архитектура представляет собой универсальный прототип, обладающий высокой степенью масштабируемости. Она может быть эффективно адаптирована для задач цифровизации широкого спектра высокотемпературных металлургических производств.

В качестве перспективного направления дальнейшей работы рассматривается верификация предложенного алгоритмического обеспечения непосредственно на реальных промышленных объектах. Также планируется работа над оптимизацией вычислительных мощностей системы для внедрения в режиме реального времени на конкретных типах печей с учетом марки выплавляемой меди.

Список литературы

Журнальные статьи

1. Norgate, T., & Haque, N. (2010). Energy and greenhouse gas impacts of mining and mineral processing operations. *Journal of Cleaner Production*, 18(3), 266–274. <https://doi.org/10.1016/j.jclepro.2009.09.020>
2. Zhao, L., Zhu, D., Liu, D., Pan, J., & Zheng, Q. (2023). Prediction and optimization of matte quality in ISA furnace based on GA-BP neural network. *Applied Sciences*, 13(7), 4246. <https://doi.org/10.3390/app13074246>
3. Li, J., Wang, H., Zhang, R., & Chen, Y. (2024). Prediction of ladle furnace refining endpoint temperature based on particle swarm optimization algorithm and long short-term memory neural network. *Journal of Materials Metallurgy*, 23(1), 1–12. <https://doi.org/10.1007/s42243-023-01100-6>
4. Li, B., Chen, G., & Wang, J. (2023). Optimizing temperature setting for decomposition furnace based on attention mechanism and neural networks. *Sensors*, 24(1), 78. <https://doi.org/10.3390/s24010078>
5. Duan, Y., Dai, J., Luo, Y., & Chen, G. (2024). Multi-step furnace temperature prediction model for regenerative aluminum smelting based on reversible instance normalization–convolutional neural network–transformer. *Processes*, 12(11), 2438. <https://doi.org/10.3390/pr12112438>
6. Pi, R., Fan, Z., & Xu, B. (2024). Electric arc furnaces scheduling under electricity price volatility with reinforcement learning. *IEEE Transactions on Power Systems*. Advance online publication. <https://doi.org/10.48550/arXiv.2512.09293>
7. Estay, H., Lois-Morales, P., Montes-Atenas, G., & Ruiz Del Solar, J. (2023). On the challenges of machine learning in mining and extractive metallurgy. *Minerals*, 13(6), 788. <https://doi.org/10.3390/min13060788>
8. Flores, V., Keith, B., & Leiva, C. (2020). Using artificial intelligence techniques to improve the prediction of copper recovery by leaching. *Journal of Sensors*, 2020, 2454875. <https://doi.org/10.1155/2020/2454875>
9. Asghari, P., Rahmani, A. M., & Javadi, H. H. S. (2023). A survey on the role of industrial IoT in manufacturing for implementation of smart industry. *Sensors*, 23(21), 8958. <https://doi.org/10.3390/s23218958>
10. Ladegourdie, M., & Kua, J. (2022). Performance analysis of OPC UA for industrial interoperability towards Industry 4.0. *IoT*, 3(4), 507–525. <https://doi.org/10.3390/iot3040027>

Книги

11. Schlesinger, M. E., King, M. J., Sole, K. C., & Davenport, W. G. (2011). Extractive metallurgy of copper (5th ed.). Elsevier.

Труды конференций

12. Gholami, A., Asgari, K., Khoshdast, H., & Hassanzadeh, A. (2022). A hybrid geometallurgical study combining historical data and deep learning at a copper ore mine. *Physicochemical Problems of Mineral Processing*, 58, 147841.
13. Ribeiro, I. P., Pedrosa, A., & Correia, A. (2018). Machine learning approach for predictive maintenance in Industry 4.0. In *Proceedings of the 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA)* (pp. 1–4). IEEE.
<https://doi.org/10.1109/ETFA.2018.8449150>
14. Zhang, Y., & Yang, J. (2021). IoT-based smart energy monitoring systems: A review. *Renewable and Sustainable Energy Reviews*, 145, 111125.
<https://doi.org/10.1016/j.rser.2021.111125>