ИНТЕЛЛЕКТУАЛЬНЫЕ ТЕХНИЧЕСКИЕ СИСТЕМЫ В ПРОИЗВОДСТВЕННОЙ И ПРОМЫШЛЕННОЙ ПРАКТИКЕ

INTELLIGENT TECHNICAL SYSTEMS IN PRODUCTION AND INDUSTRIAL PRACTICE

2.3.3 *АВТОМАТИЗАЦИЯ И УПРАВЛЕНИЕ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ И ПРОИЗВОДСТВАМИ (ТЕХНИЧЕСКИЕ НАУКИ)*

AUTOMATION OF MANUFACTURING AND TECHNOLOGICAL PROCESSES

DOI: 10.33693/2313-223X-2025-12-2-142-149

УДК: 519.254

ГРНТИ: 82.29.09

EDN: RBANJL

Прогнозирование выхода концентрата кремниевой руды с помощью методов машинного обучения

О.С. Буслаева[a] ©, В.А. Конов[b] ©, А.Г. Палей[c] ©, Н.А. Ушаков[d] ©

Южно-Уральский государственный университет, г. Челябинск, Российская Федерация

[a] **E-mail: buslaevaos@susu.ru**

[b] **E-mail: konovva@susu.ru**

[c] **E-mail: paleiag@susu.ru**

[d] **E-mail: kashak2000@gmail.com**

Аннотация. В статье рассматривается применение методов машинного обучения для прогнозирования выхода концентрата кремниевой руды. Проблема контроля содержания кремнезема является существенной для горнодобывающей промышленности, так как от этого зависит качество конечного продукта и его себестоимость [9; 10]. В процессе исследования данные, полученные с флотационной фабрики после проведения их предварительной обработки, были использованы на предмет выделения наиболее динамично изменяющихся факторов (показателей флотации). Были обучены модели случайного леса и рекуррентной сверточной нейронной сети LSTM с разным набором входных признаков. Оценка качества используемых моделей производилась с помощью метрик среднеквадратичной ошибки (MSE), средней абсолютной ошибки (MAE) и коэффициента детерминации (R-squared). В результате экспериментов было установлено, что моментальные показатели флотации в меньшей степени влияют на улучшение качества прогноза, а уникальные переменные, взятые с различным лагом, приводят к повышению точности. *Результаты исследования* могут быть использованы на предприятиях, занимающихся переработкой кремниевой руды, для более полной автоматизации и оптимизации процессов управления флотацией.

Ключевые слова: обогащение руды, анализ данных, машинное обучение, нейронные сети

ОБРАЗЕЦ ЦИТИРОВАНИЯ: Буслаева О.С., Конов В.А., Палей А.Г., Ушаков Н.А. Прогнозирование выхода концентрата кремниевой руды с помощью методов машинного обучения // Computational Nanotechnology. 2025. Т. 12. № 2. С. 142–149. DOI: 10.33693/2313-223X-2025-12-2-142-149. EDN: RBANJL

DOI: 10.33693/2313-223X-2025-12-2-142-149

Forecasting Silicon Ore Concentrate Yield Using Machine Learning Methods

O.S. Buslaeva[a] ©, V.A. Konov[b] ©, A.G. Palei[c] ©, N.A. Ushakov[d] ©

South Ural State University, Chelyabinsk, Russian Federation

[a] **E-mail: buslaevaos@susu.ru**

[b] **E-mail: konovva@susu.ru**

[c] **E-mail: paleiag@susu.ru**

[d] **E-mail: kashak2000@gmail.com**

Abstract. The article effectively applies machine learning methods to predict the production of silicon ore concentrate. The problem of silica content control is a problem for the mining industry, since the quality of the final product and its cost depend on it [9; 10]. During the study, the data obtained from the flotation plant after their preliminary processing were used to identify the most dynamically changing factors (flotation indicators). Random forest and recurrent convolutional neural network LSTM models were trained with different sets of input features. The quality of the models used was assessed using the mean square error (MSE), mean absolute error (MAE) and determination coefficient (R-squared) metrics. *As a result of the experiments*, it was found that instant flotation indicators have a lesser effect on improving the quality of the forecast, and unique variables taken with different lags lead to an increase in accuracy. The results of the study can be used at enterprises engaged in the processing of silicon ore for more complete automation and optimization of flotation control processes.

Key words: ore beneficiation, data analysis, machine learning, neural networks

FOR CITATION: Buslaeva O.S., Konov V.A., Palei A.G., Ushakov N.A. Forecasting Silicon Ore Concentrate Yield Using Machine Learning Methods. *Computational Nanotechnology*. 2025. Vol. 12. No. 2. Pp. 142–149. (In Rus.). DOI: 10.33693/2313-223X-2025-12-2-142-149. EDN: RBANJL

ВВЕДЕНИЕ

Для переработки на металлургических предприятиях используется руда с определенным содержанием добываемого металла. Руду обычно обогащают, т.е. искусственно повышают содержание металлов в сырье, поступающем на металлургическую переработку. Одним из важнейших показателей эффективности процесса производства на горно-обогатительных комбинатах (ГОКах) является выход концентрата – количество полезного вещества, которое удается извлечь из исходной руды. От содержания металла в перерабатываемом сырье зависит себестоимость готовой продукции после ее обогащения. Прогнозирование этого показателя позволяет заранее оценить эффективность производства и принять меры по его улучшению.

Процесс обогащения руды и, в частности, флотация – это многопараметрическая система с нелинейными зависимостями между характеристиками. Для более эффективного управления от операторов требуется глубокое понимание процессов, которые происходят при обогащении.

Входная руда, поступающая на обработку, не всегда однородна, поэтому для одних и тех же этапов обработки характерны разные реакции, что влияет на количество этапов рециркуляции пульпы для дополнительной переработки. Все это отражается на итоговом качестве концентрата.

Для правильной и эффективной реакции на изменение входящей руды необходимо менять уставки в системе управления для всех объектов на протяжении всего процесса переработки и флотации, в частности.

Определение нужных уставок зависит от степени понимания процесса и способности спрогнозировать его дальнейшее изменение. Для помощи в принятии таких решения используется отслеживание качества входного и выходного материала с помощью лабораторных исследований, на проведение которых требуется много времени.

Цикл обработки сырья может занимать время от 40 минут до 1,5 часов. На него может влиять состав руды, класс крупности руды, схема работы или особенности конкретного производства, поэтому те изменения, которые вносит оператор могут быть неактуальны в настоящий момент, так как нет актуальных корректных данных. То есть вносимые изменения почти всегда носят прогнозный, упреждающий характер, основываясь на понимании оператора.

Таким образом, все описанные проблемы делают процесс управления сложным и не всегда прозрачным, а опыт оператора влияет на показатели готового продукта. Для снижения влияния человеческого фактора требуется система планирования и прогнозирования, которая отвечает требованиям точности.

ОСНОВНАЯ ЧАСТЬ

Традиционно для оценки выхода концентрата используются эмпирические методы [1–3], однако такие подходы часто оказываются ограниченными в своей способности учитывать все факторы, влияющие на процесс обогащения руды. В то же время современные технологии, в частности методы машинного обучения, позволяют обрабатывать большие объемы данных и выявлять скрытые закономерности, недоступные традиционным подходам [4–8].

В статье исследуется возможность применения методов машинного обучения для прогнозирования выхода концентрата кремниевой руды. Данные были собраны с реальной обогатительной фабрики и представляют собой файл с расширением csv.

В табл. 1 приведены описание полей используемого файла.

Таблица 1

Описание данных (тип данных: Float64) [Data description (data type: Float64)]

Наименование [Name]	Описание [Discription]
% Iron Feed	Содержание железа в руде после флотации, % [Percentage of iron content in ore in flotation feed]
% Silica Feed	Содержание кремния в руде после флотации, % [Percentage of silicon content in ore in flotation feed]
Starch Flow	Расход крахмала [Starch consumption]
Amine Flow	Расход амина [Amine consumption]
Ore Pulp Flow	Расход пульпы в процессе флотации, т/ч [Pulp consumption in flotation feed, t/h]
Ore Pulp pH	pH пульпы [Pulp pH]
Ore Pulp Density	Плотность пульпы [Pulp density]
Flotation Column Air Flow 01 … 07	Расход воздуха во флотационной установке [Air consumption in flotation machine]
Flotation Column Level 01 … 07	Уровень пены на поверхности флотационной установки [Foam level on flotation machine surface]
% Iron Concentrate	Содержание железа в концентрате, % (лабораторный анализ) [Percentage of iron content in concentrate (laboratory analysis)]
% Sillica Concentrate	Содержание кремния, % (лабораторный анализ) [Percentage of silicon content (laboratory analysis)]

Представленные данные получены с обогатительной фабрики за 7 месяцев. Как видно из рис. 1, в исходных данных содержится 737 453 наблюдения по 24 показателям.

В данных (рис. 1) содержится дата с меткой даты и времени за каждый час. Причем периодичность съема значений некоторых показателей составляла 20 минут, а часть показателей снимались с часовой периодичностью. Набор данных состоит из четырех групп показателей. % Iron Feed и % Silica Feed – это показатели качества пульпы железной руды непосредственно перед ее подачей на флотационную установку. Следующие 5 показателей, например, такие как Amina Flow, Starch Flow и др., являются переменными, влияющие на качество руды в конце процесса. Третья группа, состоящая из 14 показателей, представляет собой данные процесса (уровень и поток воздуха внутри колонн флотации). Последняя группа % Iron Concentrate и % Sillica Concentrate – это целевые показатели в виде процента содержания железа и кремнезема в конечном концентрате. В процессе подготовки данных к анализу были устранены пропуски по наблюдениям за определенные периоды и все показатели были стандартизированы в целях приведения к единому масштабу

```
 #   Column                        Non-Null Count   Dtype
---  ------                        --------------   -----
 0   % Iron Feed                   737453 non-null  float32
 1   % Silica Feed                 737453 non-null  float32
 2   Starch Flow                   737453 non-null  float32
 3   Amina Flow                    737453 non-null  float32
 4   Ore Pulp Flow                 737453 non-null  float32
 5   Ore Pulp pH                   737453 non-null  float32
 6   Ore Pulp Density              737453 non-null  float32
 7   Flotation Column 01 Air Flow  737453 non-null  float32
 8   Flotation Column 02 Air Flow  737453 non-null  float32
 9   Flotation Column 03 Air Flow  737453 non-null  float32
 10  Flotation Column 04 Air Flow  737453 non-null  float32
 11  Flotation Column 05 Air Flow  737453 non-null  float32
 12  Flotation Column 06 Air Flow  737453 non-null  float32
 13  Flotation Column 07 Air Flow  737453 non-null  float32
 14  Flotation Column 01 Level     737453 non-null  float32
 15  Flotation Column 02 Level     737453 non-null  float32
 16  Flotation Column 03 Level     737453 non-null  float32
 17  Flotation Column 04 Level     737453 non-null  float32
 18  Flotation Column 05 Level     737453 non-null  float32
 19  Flotation Column 06 Level     737453 non-null  float32
 20  Flotation Column 07 Level     737453 non-null  float32
 21  % Iron Concentrate            737453 non-null  float32
 22  % Silica Concentrate          737453 non-null  float32
dtypes: float32(23)
memory usage: 70.3 MB
```

Рис. 1. Информация о датасете

Fig. 1. Dataset information

На столбчатой диаграмме (рис. 2) по среднему количеству уникальных значений в час видно, что обновление данных о самом процессе флотации происходит примерно 3 раза в час. В то же время процент содержания металла в концентрате обновляется 11 и 15 раз для железа и кремния соответственно, а процент содержания металла в питании не обновляется в течение часа

При анализе среднего количество уникальных значений за день было выявлено, что процент содержания металла в питании обновляется 3 раза в день, то есть изменение значения происходит один раз в 8 часов (рис. 3).

Выявленные особенности данных и специфика решения задачи приводят к необходимости фильтрации данных по принципу отбора первого наблюдения в течение каждого часа. После подобной обработки получено 3472 ненулевых наблюдений, и целевая переменная имеет следующие статистики (табл. 2). Кроме того, флотация – это динамический процесс с определенным запаздыванием, а это значит, что обучение модели с переменными, взятыми в один и тот же момент времени, не приведет к точным результатам. Другими словами, процент концентрация кремния в указанной временной метке не связан с потоком реагентов в одинаковой временной метке, поэтому одной из самых сложных задач было найти правильный лаг между факторными переменными и целевой переменной.

В рассматриваемой задаче лаг целевой переменной варьируется на уровне 1,2 и 3 часа с целью выбора оптимального значения.

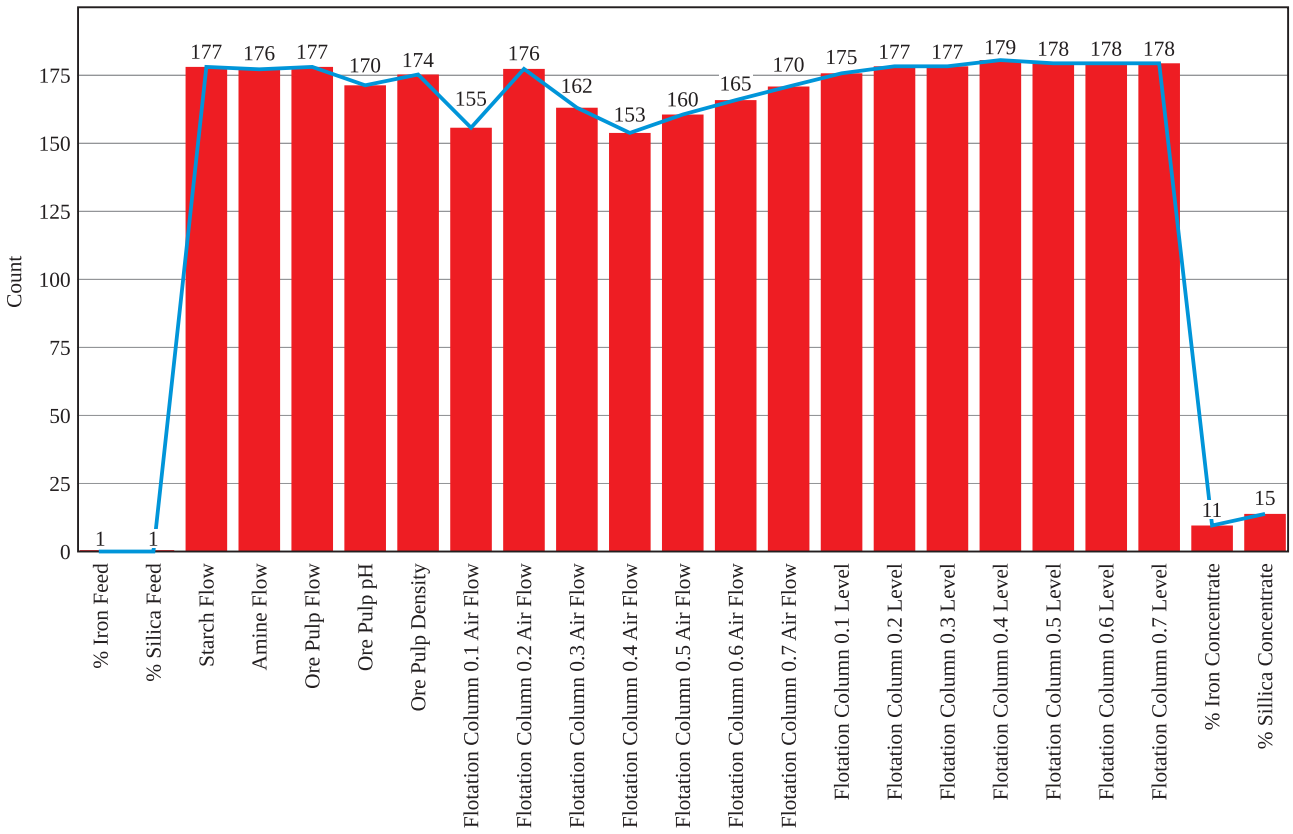

Рис. 2. Среднее количество уникальных значений за час

Fig. 2. Average unique values per hour

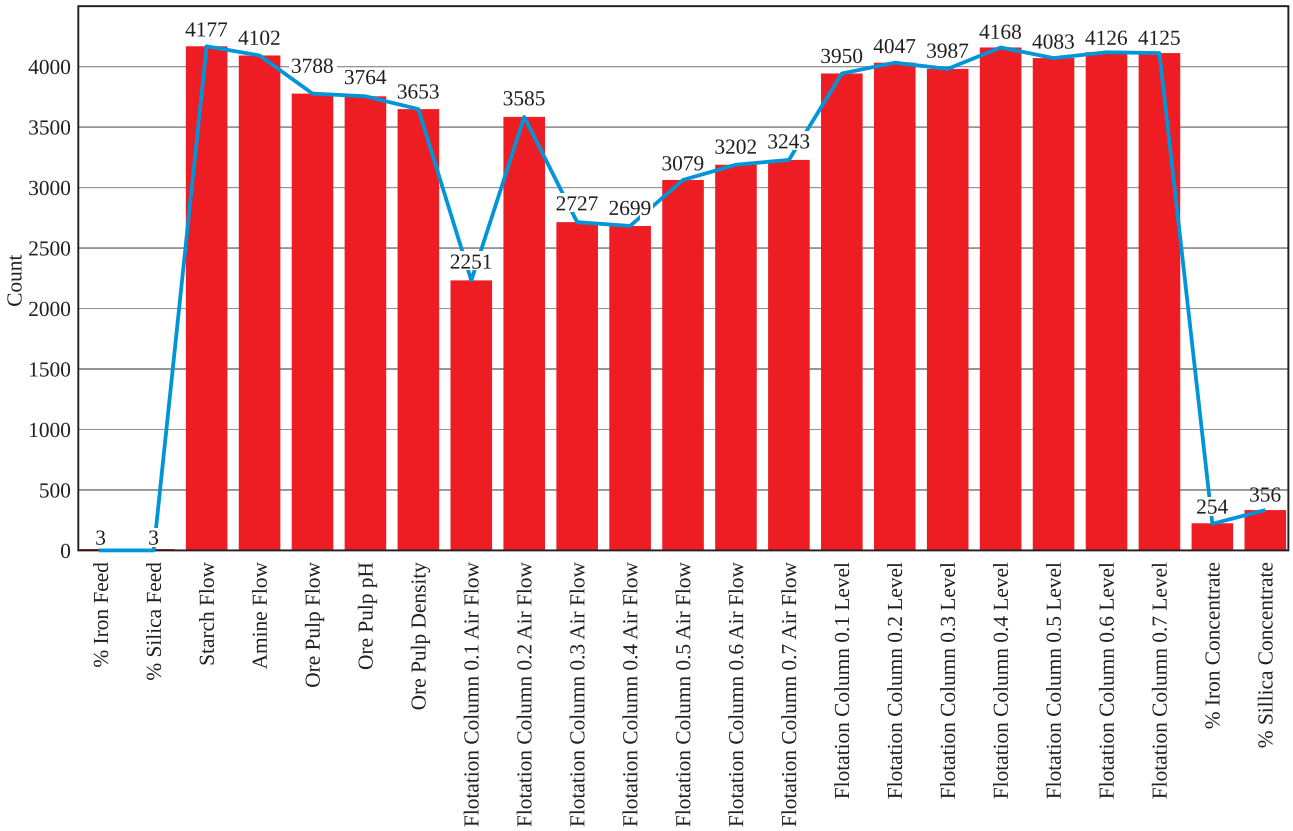

Рис. 3. Среднее количество уникальных значений за день

Fig. 3. Average unique values per day

Таблица 2

Статистики процента содержания кремния в концентрате [Statistics of silicon content percentage in concentrate]

Название статистики [Statistic name]	Значение [Value]
Количество наблюдений [Quantity of monitoring]	3472
Среднее [Average]	2,34
Стандартное отклонение [Standard deviation]	1,13
Минимальное значение [Minimum value]	0,60
Первый процентиль [First percentile]	1,45
Второй процентиль [Second percentile]	1,99
Третий процентиль [Third percentile]	3,02
Максимальное значение [Maximum value]	5,53

В матрице (рис. 4) представлены коэффициенты корреляции Пирсона для всех количественных признаков. Присутствует сильная отрицательная корреляционная связь между процентом содержания кремния и железа в исходной пульпе, т.е. данные переменные коллинеарны. В этом случае трудно определить степень влияния каждой из переменных на целевые переменные, а также могут возникнуть ошибки при расчете оценочных метрик [9]. Поэтому первую переменную из модели можно исключить.

Кроме того, из рис.4 следует, что коэффициенты корреляции между остальными факторными переменными и целевой существенно невелики, что означает что ни одна из них не оказывает преобладающее влияние на ход процесса. Поэтому для получения большей адекватности модели в ней были использованы все представленные показатели.

Для решения задачи прогнозирования концентрации кремния использовались модели случайного леса, рекуррентные нейронные сети (LSTM) и простейшая (наивная) модель, в которой значение прогноза равно последнему текущему значению. Данные разделялись на обучающую (80%) и тестовую (20%) выборку.

ВЫВОДЫ

После проведения экспериментов качество прогноза каждой модели оценивалось по нескольким метрикам (табл. 3).

- *RMSE* (*Root Mean Squared Error*). Измеряет корень средней суммы квадратной разности между фактическим значением и прогнозируемым значением для всех значений наблюдений. Такую метрику легко интерпретировать, так как она имеет те же единицы измерения, что и целевая переменная [3].

- *MAE* (*Mean Absolute Error*). Метрика измеряет среднюю сумму абсолютной разницы между фактическим и прогнозируемым значением.
- *MASE* (*Mean Absolute Scaled Error*). Средняя абсолютная масштабируемая погрешность является мерой точности прогнозов. Это средняя абсолютная погрешность прогнозных значений, деленная на среднюю абсолютную погрешность одношагового (по последнему известному значению) прогноза [8].
- R^2 (*R-squared*). Коэффициент детерминации показывает уровень связи между факторами регрессии и целевой переменной. Это отношение суммы квадратов отклонений от среднего переменной, объясняемой моделью к остаточной сумме квадратов отклонений целевой переменной [8].

По данным табл. 3 наиболее обоснованным представляется вывод о преимуществе нейронной сети LSTM с тремя лаговыми переменными. Метрика MASE минимальна и обеспечит малые средние ошибки, что важно для задач, связанных с контролем качества продукции, где точность прогнозов имеет решающее значение. Коэффициент детерминации максимален, что говорит о достаточной степени соответствия модели реальному процессу и подтверждает ее пригодность для прогнозирования содержания кремнезема в реальных производственных условиях [10].

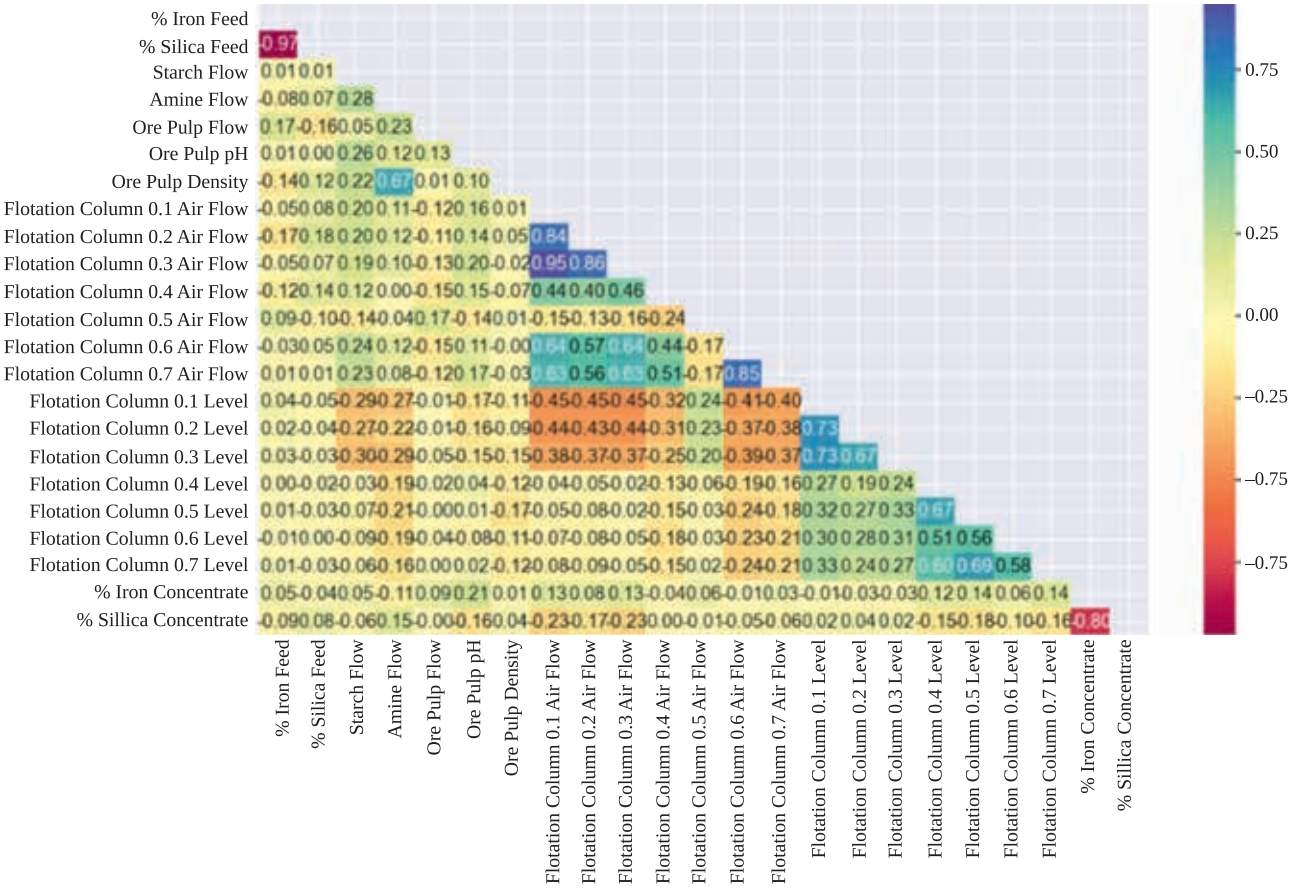

Рис. 4. Матрица корреляции

Fig. 4. Correlation matrix

Таблица 3

Сравнительная таблица моделей [Model comparison table]

Название модели [Name of model]	RMSE	MASE	MAE	R-squared
Наивная модель [Simple model]	0,77	1,00	0,49	0,57
RandomForestRegressor	0,78	1,23	0,60	0,55
LSTM (лаговые переменные) [LSTM (lag variable)]	0,72	0,95	0,46	0,61
LSTM (все переменные) [LSTM (all variable)]	0,75	1,05	0,51	0,58

ЗАКЛЮЧЕНИЕ

Результаты исследований могут быть использованы на предприятиях, занимающихся переработкой кремниевой руды. Показано, что для прогнозирования выхода кремния обосновано использование выбранного метода машинного обучения (рекурентной нейронной сети LSTM) с лаговыми переменными. Перспективным является внедрение данной модели для решения следующей задачи: путем моделирования широкого спектра входных данных определить их набор для получения требуемого значения процента содержания концентрата кремния, чем обеспечить оптимизацию процесса управления флотацией. Для более точного моделирования предполагается продолжение исследования с увеличением объема исходных данных и с учетом особенностей процесса обогащения на конкретной горно-обогатительной фабрике.

Литература

1. *Pavlov A.V.*, *Polinov A.A.*, *Spirin N.A.* et al. Use of model sys-tems for solving new technological problems in blast-furnace production // Metallurgist. 2017. No. 61 (5-6). Pp. 448–454. DOI: 10.1007/s11015-017-0516-7.
2. *Spirin N.A.*, *Polinov A.A.*, *Gurin I.A.* et al. Information system for real-time prediction of the silicon content of iron in a blast furnace // Metallurgist. 2020. No. 63 (9-10). Pp. 898–905. DOI: 10.1007/s11015-020-00907-y.
3. *Павлов А.В.* и др. Информационно-моделирующая система прогнозирования состава и свойств конечного шлака в до-менной печи в режиме реального времени // Известия выс-ших учебных заведений. Черная металлургия. 2023. Т. 66.№ 2. С. 244–252. DOI: 10.17073/0368-0797-2023-2-244-252.
4. *Song J.*, *Xing X.*, *Pang Z.*, *Lv M.* Prediction of silicon content in the hot metal of a blast furnace based on FPA-BP model // Metals. 2023. No. 13. P. 918. DOI: 10.3390/ met13050918.
5. *Спирин Н.А.*, *Лавров В.В.*, *Рыболовлев В.Ю.* и др. Цифровая трансформация пирометаллургических технологий: состояние, научные проблемы и перспективы развития // Известия высших учебных заведений. Черная металлургия. 2021. № 64 (8). С. 588–598. DOI: 10.17073/0368-0797-2021-8-588-598.
6. *Zhou H.*, *Zhang Y.*, *Yang C.*, *Sun Y.* Deep learning based silicon content estimation in ironmaking process // IFAC-PapersOnLine. 2020. Vol. 53. No. 2. Pp. 10737–10742. DOI: 10.1016/j.ifacol.2020.12.2854.
7. *Фомичева С.Г.*, *Конев А.В.* Адаптивная система управления содержанием оксида кремния в шлаках при переработке медно-никелевых руд // Программные продукты и системы. 2014. № 3 (107). С. 131–140. EDN: TPOVTV.
8. *Соколов Б.В.*, *Юсупов Р.М.* Концептуальные основы оценивания и анализа качества моделей и полимодельных комплексов // Известия РАН. Теория и системы управления. 2004. № 6. С. 6–16. EDN: OSKXTP.
9. *Kaung P.A.*, *Isakov A.E.*, *Pan ilov I.A.* et al. Principles for forming environmentally safe and economically effective sustainable development of geo resources // MIAB. Mining Inf. Anal. Bull. 2024. No. 7-1. Pp. 159–175.
10. *Yang K.*, *Hu C.* A prediction method of silicon content in hot metal of blast furnace // Metallurgiya. 2022. Vol. 61. No. 3-4. Pp. 581–584.
11. *Drumond P.*, *Kappes D.*, *Moraes C. de* et al. Soft sensor: Machine learning tradicional ou deep learning? // 22°. Seminário de Automação e TI. São Paulo, 2018. Pp. 231–242. DOI: 10.5151/2237-0234-31915.

References

1. *Pavlov A.V.*, *Polinov A.A.*, *Spirin N.A.* et al. Use of model sys-tems for solving new technological problems in blast-furnace production. *Metallurgist*. 2017. No. 61 (5-6). Pp. 448–454. DOI: 10.1007/s11015-017-0516-7.
2. *Spirin N.A.*, *Polinov A.A.*, *Gurin I.A.* et al. Information system for real-time prediction of the silicon content of iron in a blast furnace. *Metallurgist*. 2020. No. 63 (9-10). Pp. 898–905. DOI: 10.1007/s11015-020-00907-y.
3. *Pavlov A.V.*, *Spirin N.A.*, *Gurin I.A.* et al. Information-modeling system for prediction of the composition and properties of final slag in a blast furnace in real time. *Izvestiya. Ferrous Metallurgy*. 2023. No. 66 (2). Pp. 245–252. (In Rus.). DOI: 10.17073/0368-0797-2023-2-245-252.
4. *Song J.*, *Xing X.*, *Pang Z.*, *Lv M.* Prediction of silicon content in the hot metal of a blast furnace based on FPA-BP model. *Metals*. 2023. No. 13. P. 918. DOI: 10.3390/ met13050918.
5. *Spirin N.A.*, *Lavrov V.V.*, *Rybolovlev V.Yu.* et al. Digital transformation of pyrometallurgical technologies: State, scientifc problems and prospects of development. *Izvestiya. Ferrous Metallurgy*. 2021. No. 64 (8). Pp. 588–598. (In Rus.). DOI: 10.17073/0368-0797-2021-8-588-598.
6. *Zhou H.*, *Zhang Y.*, *Yang C.*, *Sun Y.* Deep learning based silicon content estimation in ironmaking process. *IFAC-PapersOnLine*. 2020. Vol. 53. No. 2. Pp. 10737–10742. DOI: 10.1016/j.ifacol.2020.12.2854.
7. *Fomicheva S.G.*, *Konev A.V.* Adaptive control system for silicon oxide concentration in slags at processing copper-nickel ores. *Software & Systems*. 2014. No. 3 (107). Pp. 31–140. (In Rus.). EDN: TPOVTV.
8. *Sokolov B.V.*, *Yusupov R.M.* The conceptual and technical basics for qualimetry of models and multiple-model complexes. *News of RAS. Theory and Control Systems*. 2004. No. 6. Pp. 6–16. (In Rus.). EDN: OSKXTP.
9. *Kaung P.A.*, *Isakov A.E.*, *Pan ilov I.A.* et al. Principles for forming environmentally safe and economically effective sustainable development of geo resources. *MIAB. Mining Inf. Anal. Bull*. 2024. No. 7-1. Pp. 159–175.
10. *Yang K.*, *Hu C.* A prediction method of silicon content in hot metal of blast furnace. *Metallurgiya*. 2022. Vol. 61. No. 3-4. Pp. 581–584.
11. *Drumond P.*, *Kappes D.*, *Moraes C. de* et al. Soft sensor: Machine learning tradicional ou deep learning? 22°. Seminário de Automação e TI. São Paulo, 2018. Pp. 231–242. DOI: 10.5151/2237-0234-31915.

Статья проверена программой Антиплагиат. Оригинальность – 68,31%

Рецензент: *Горкуша О.А.*, кандидат физико-математических наук; старший научный сотрудник; Хабаровское отделение Института прикладной математики Дальневосточного отделения Российской академии наук

Статья поступила в редакцию 27.05.2025, принята к публикации 21.06.2025
The article was received on 27.05.2025, accepted for publication 21.06.2025

СВЕДЕНИЯ ОБ АВТОРАХ

Буслаева Ольга Станиславовна, кандидат технических наук; доцент, кафедра цифровой экономики и информационных технологий; Южно-Уральский государственный университет; г. Челябинск, Российская Федерация. ORCID: 0000-0002-7763-527X; Scopus ID: 57221265394; РИНЦ Author ID: 282982; SPIN-код: 7432-6003; E-mail: buslaevaos@susu.ru

Конов Вячеслав Анатольевич, кандидат технических наук; доцент, кафедра цифровой экономики и информационных технологий; Южно-Уральский государственный университет; г. Челябинск, Российская Федерация. ORCID: 0009-0004-8489-2997; РИНЦ Author ID: 653893; SPIN-код: 2502-5832; E-mail: konovva@susu.ru

Палей Александр Гилич, кандидат технических наук; доцент, кафедра цифровой экономики и информационных технологий; Южно-Уральский государственный университет; г. Челябинск, Российская Федерация. ORCID: 0009-0005-3793-301X; Scopus ID: 57205615841; РИНЦ Author ID: 651842; SPIN-код: 5542-6772; E-mail: paleiag@susu.ru

Ушаков Николай Александрович, аспирант, кафедра цифровой экономики и информационных технологий; Южно-Уральский государственный университет; г. Челябинск, Российская Федерация. E-mail: kashak2000@gmail.com

ABOUT THE AUTHORS

Olga S. Buslaeva, Cand. Sci. (Eng.); associate professor, Department of Digital Economy and Computer Science; South Ural State University; Chelyabinsk, Russian Federation. ORCID: 0000-0002-7763-527X; Scopus ID: 57221265394; RSCI Author ID: 282982; SPIN-code: 7432-6003; E-mail: buslaevaos@susu.ru

Vyacheslav A. Konov, Cand. Sci. (Eng.); associate professor, Department of Digital Economy and Computer Science; South Ural State University; Chelyabinsk, Russian Federation. ORCID: 0009-0004-8489-2997; RSCI Author ID: 653893; SPIN-code: 2502-5832; E-mail: konovva@susu.ru

Aleksandr G. Palei, Cand. Sci. (Eng.); associate professor, Department of Digital Economy and Computer Science; South Ural State University; Chelyabinsk, Russian Federation. ORCID: 0009-0005-3793-301X; Scopus ID: 57205615841; RSCI Author ID: 651842; SPIN-code: 5542-6772; E-mail: paleiag@susu.ru

Nikolai A. Ushakov, postgraduate student; Department of Digital Economy and Computer Science; South Ural State University; Chelyabinsk, Russian Federation. E-mail: kashak2000@gmail.com