

УДК 004.896

**ПРОГНОСТИЧЕСКИЕ МОДЕЛИ ДЛЯ ОПРЕДЕЛЕНИЯ ПРОИЗВОДИТЕЛЬНОСТИ
ИЗМЕЛЬЧИТЕЛЬНОГО ОБОРУДОВАНИЯ НА ОБОГАТИТЕЛЬНЫХ ФАБРИКАХ**

Гзогян Семен Райрович, аспирант

Белгородский государственный национальный исследовательский университет

**PREDICTIVE MODELS FOR DETERMINING THE PRODUCTIVITY OF GRINDING
EQUIPMENT AT MINING PLANTS**

Gzogyan Semyon Rayrovich, postgraduate student

Belgorod State National Research University

В статье представлены результаты построения регрессионных моделей и их нейросетевой верификации, позволяющих проводить оценку текущей/прогнозной производительности обогатительной фабрики при измельчении железорудного сырья.

Ключевые слова: моделирование, регрессионная модель, нейросетевая модель, обогатительная фабрика, технологический процесс, производительность.

The article presents the results of constructing regression models and their neural network verification, which allow assessing the current/forecasted productivity of a beneficiation plant when grinding iron ore raw materials.

Keywords: modeling, regression model, neural network model, enrichment plant, technological process, productivity.

Сегодня создание и модернизация современных АСУТП и АСУП на обогатительных фабриках (ОФ) горнообогатительных комбинатов (ГОК) связаны одновременно как с сохранением традиционных основ построения автоматизированных систем, так и с расширением возможностей интерпретации производственных данных на основе цифровых технологий Индустрии 4.0, что позволяет обеспечить значительный технико-экономический и эколого-экономический эффекты. В том числе, в данном аспекте актуальны методы предиктивной аналитики, обеспечивающие установление научно обоснованных обратных связей в системах рассматриваемого класса, актуализацию выработки управляющих решений в сфере планирования производства на основе высокоточных модельных оценок и прогнозирования результатов производственных операций и процессов с уче-

том изменений максимального числа технологических параметров, а также с учетом производственных особенностей.

Основными причинами необходимости использования подобных подходов являются [1]:

- сложность и высокая динамика самих объектов управления;
- наличие значительных неопределённостей в параметрах, которые используются для построения моделей объектов управления и механизмов управления;
- повышенные требования к результатам производства, включая вопросы экологической безопасности.

Различными исследователями продемонстрированы перспективы и результаты применения технологий предиктивной аналитики, в том числе на основе цифрового моделирования, для организации технологических процессов процессов добычи и обогащения, как показано, например, в работах [2,3].

Следует особо отметить, что измельчение руды – это не только наиболее важный, но и наиболее дорогостоящий технологический процесс на ГОК, так как на него приходится около 50% от всех производственных затрат. При этом данный процесс является многофакторным и нестационарным, неустойчивым в режимах функциональной нестабильности технологического процесса, параметры которого нелинейно изменяются в постоянной взаимосвязи. Внедрение новых методов автоматизации данного процесса с применением цифровых технологий позволяет в целом повлиять на повышение производительности ОФ. Это подтверждено и количественными оценками, например, новый метод автоматизированного управления измельчением, предложенный фирмы «Xstrata Nickel» для профильного завода «Strathcona» позволил повысить энергетическую эффективность используемых мельниц на 5,5-7,1 % [4].

Однако вопросы, связанные с задачами прогнозирования, в целом освещены не полно, а приведенные прогнозные оценки являются по большей части приближенными и имеющими неприемлемый уровень достоверности. Особенно важно отметить, что описанные в литературе схемы оценки эффективности производства в основном построены как функции от технологических параметров и не учитывают ее связь с минералогическим составом руды, являются упрощенными и не могут быть использованы в качестве надежного прогнозного инструмента. Описанные в источниках подходы при решении задачи прогнозирования в большинстве сформированы без учета многофакторности рассматриваемой системы, которая, как указано выше, относится к слабо формализуемым и требующим для полноценного исследования применения многокомпонентного подхода, включающего в себя различные математические модели.

Автором представлены результаты разработки предиктивной регрессионной модели, в которой учитывается полный спектр возможных технологических параметров процесса измельчения. Адекватность разработанной модели основана на последовательной оптимизации массива производственных данных и верифицирована нейросетевой моделью.

Итак, для актуализации адекватных моделей, необходимо проведение предварительной оптимизации баз данных (БД), полученных при контроле реальной работы измельчительного оборудования. Использовались данные, предоставленные Лебединским ГОКом, всего 432 набора значений, где значению 432 соответствует количество зарегистрированных суточных наборов параметров [5]: 28 технологических параметров $TP = \{TP_1, \dots, TP_j, \dots, TP_J\}$ и Y «Производительность головных валковых мельниц». Таким образом общее количество $N = J+1$. В исследуемом случае, $J = 27$, $N = 28$.

Осуществлено построение полей корреляции всех входных параметров TP_j ($j=\overline{1,J}$) с выходным параметром Y . Использовалась среда *MathLab R2021a*. Сделан первичный вывод о значимости всех параметров. На следующем этапе были разработаны ряд простых предсказательных моделей с использованием различных методов: деревья решений; Fine, Medium и Coarse Tree; линейная регрессия. Наилучший результат показала линейная регрессионная модель, точность предсказания которой по значению среднеквадратичной ошибки $\sigma_{кв}$ составила 27,4, что составило менее 4,6% (среднее значение фактической производительности за период $Y = 608,7$ т/ч). Также был проведен анализ графиков остатков (отклонений), который показал, что для основного спектра данных диапазон отклонений составляет ~ 60%, а ~ 25% находится в диапазоне с вдвое большей шириной. Кроме того, у ~ 3% точек отклонения значений, выданных предиктивной моделью, от фактических

Y составляют более 10%. Данный анализ позволил сделать вывод о рациональности отброса ~3% суточных наборов данных, где значения Y находятся на границах кривой их распределения.

Оценивалась значимость факторов-предикторов модели с использованием метода деревьев решений. Использовалась среда *MathLab*, функция *plotPredictorImportance*, в результате чего были извлечены характеристики важности для всех TP_j ($j=1,27$). Также были проведены подобные оценки на основе матрицы парных корреляций. Проведенный анализ полученных оценок позволил уменьшить размерность модели до $J = 12$.

Дальнейший анализ и оптимизация обобщенной БД основывается на построении и исследовании предварительной модели. При этом осуществлялся поиск наиболее простой модели и одновременно проводилась дальнейшее уменьшение количества входных параметров в целях уменьшения размерности результирующей модели.

Производственные данные, которые составили результирующую БД, подверглись оценке на однородность, для того чтобы снять вопрос о возможном наличии скрытых причин в производственном процессе, которые свидетельствовали бы о неправомерном их обобщенном использовании. Для этого был проведен процесс кластеризации с его последующим анализом. Использовалась среда *Matlab* с применением методов: К-средних («*K-means*»), алгоритмы «*CalinskiHarabasz*», «*gap*», число возможных классов 1,...,10; с использованием многомерного гауссовского распределения («*gmdistribution*»), алгоритм «*DaviesBouldin*». Сделан вывод об однородности полученного массива данных, что подтверждает правомерность создания и использования обобщенной БД. Кроме того, для отобранных предикторов TP_j был произведён отсев наборов суточных показателей из обобщенных БД, для которых характерны следующие признаки: значения наиболее сильно влияющих параметров, а также отклика Y располагаются в «хвостах» соответствующих распределений.

Проведённый анализ позволил пренебречь рядом незначимых параметров и снизить размерность, а именно $J = 6$. Построена регрессионная модель вида:

$$Y = C_0 + C_1 \cdot TP_1^{0.2} + C_2 \cdot TP_2^5 + C_3 \cdot TP_3^{0.2} + C_4 \cdot TP_4^{0.2} + C_5 \cdot TP_5^{0.25} + C_6 \cdot TP_6^{0.2}, \quad (1)$$

где TP_1 = «Общ.кл.-5+0» – частный выход класса крупности 5 (вес одного одного класса, выраженный в процентах от общего веса анализируемой пробы), %; TP_2 = «Кл.-0,045» – массовая доля класса «минус 0,045 мм» в концентрате, %; TP_3 = «Мелкое» – массовая доля магнетитовой разновидности с мелкими зёрнами магнетита в ней, %; TP_4 = «Круп и с.з.» – массовая доля магнетитовой разновидности с крупными и средними зёрнами магнетита в ней, %; TP_5 = «Окислен» – массовая доля содержания окисленной руды, %; TP_6 = «Хвосты, $Fe_{общ.}$ » – массовая доля общего железа в отходах обогащения руды (имеющих минимальное содержание полезного компонента), %.

Определены значения показателей качества, характеризующие её как однозначно значимую: коэффициент детерминации $R^2 = 0,75$; стандартная среднеквадратичная ошибка $\sigma_{кв} = 27,26$.

В целях верификации качества разработанной модели (1) с использованием того же массива из обобщенной БД была построена предиктивная модель в виде искусственной нейронной сети (ИНС). Была выбрана парадигма классического многослойного персептрона с прямым распространением сигнала и обратным распространением ошибки. Использована система *Matlab*, в которой формировались ИНС с числом входных нейронов $N = 6$, соответственно выбранным параметрам технологического процесса TP_j , с различным количеством скрытых слоев и нейронов в них, с использованием различных видов функций активации. Наилучший результат продемонстрировала ИНС со структурой 6-20-1, включающая один скрытый слой с двадцатью скрытыми слоями и сигмоидной функцией активации при количестве циклов обучения, равного 500. Среднее значение прогнозной производительности составляет $\bar{Y}_{ср.} = 607,7$ т/час при фактическом среднем значении $\bar{Y}_{ср.} = 609$ т/час. Анализ процессов изменения прогнозных и фактических значений производительности при варьировании набором входных данных (выбранных параметров TP_j), которые свидетельствуют как об удовлетворительном качестве моделей, так и об их высокой степени соответствия. Максимальное абсолютное отклонение прогнозного значения производительности $\bar{Y}$ от фактических Y составило 88,2 т/час для ИНС и 87,8 т/час для регрессионной модели.

Проведённые исследования позволили сделать следующие выводы:

– Качество работы регрессионной и нейросетевой моделей практически совпадает. Модели демонстрируют соответствие динамики изменения прогнозного значения производительности $\bar{Y}$ при аналогичных вариациях суточного набора TP_j .

– Наибольшая точность прогнозирования наблюдается в интервале отклонений 8 % («плюс-минус») от $\bar{Y}_{\text{ср.}} = 609$ т/час за рассмотренный период, то есть при $Y \in [560; 650]$ т/час. За данными пределами наблюдается снижение точности.

Список использованных источников

1. Баранов, В.Ф. О фабрике будущего / В.Ф. Баранов // Обогащение руд. – 2010. – № 5. – С. 41-45.
2. Осипова, Н.В. Обзор проектов и решений по цифровым двойникам для обогатительных фабрик / Н.В. Осипова // Автоматизация в промышленности. – 2023. – №.7. – С. 37-42.
3. Швабауэр, А.Я. Управление ГОКом для соблюдения решений проекта / А.Я. Швабауэр // Цифровые технологии в горном деле: тезисы докладов Всероссийской научно-технической конференции (13-16 июня 2023 г., Апатиты). – Апатиты, 2023. – С. 72-73.
4. Topalov, A.V. Neural network modeling and control of cement mills using a variable structure systems theory based on-line learning mechanism / A.V. Topalov, O. Kaynak // Journal of Process Control. – 2004. – Т. 14. – №. 5. – С. 581-589.
5. Ивашук, О.А. Построение моделей подсистемы предиктивной аналитики при автоматизированном управлении обогатительной фабрики горно-обрабатывающего комбината/О.А. Ивашук, С.Р. Гзогян, Д.В. Гончаров, А.В. Маматов // Современные наукоемкие технологии. - 2025. - №3. - С. 20-30.