

Интерпретируемая модель виртуального анализа параметров технологической среды на основе сетей Колмогорова–Арнольда

М. А. Колотов

Уфимский университет науки и технологий

Контроль плотности пульпы на горно-обогатительных комбинатах (ГОК) критически важен для управления процессом. Традиционные радиоизотопные плотномеры дорогие и требуют лицензирования, а также подвержены деградации, что приводит к недостоверным измерениям и технологическим рискам. В данной работе исследуется вопрос создания точного и надежного виртуального анализатора плотности пульпы на основе машинного обучения, менее подверженного деградации. Гипотеза заключается в том, что алгоритмы, обученные на данных с контрольно-измерительных приборов, могут оценивать плотность пульпы и с помощью них можно предсказывать возможные изменения технологического процесса. Цель исследования — найти более дешевую, безопасную и устойчивую альтернативу

Цифровизация производства; машинное обучение; прогнозирование параметров; измельчение и дробление руды

ВВЕДЕНИЕ

В работе горно-обогатительных комбинатов (ГОК) возникает необходимость измерять плотность пульпы [Виш12] (мера концентрации твердых частиц в жидкости, на основании которой принимаются решения по управлению технологическим узлом), на основе которой в дальнейшем можно производить автоматизацию фабрики [Mat16] и узла измельчения, в частности [Zat24].

Для оценки плотности пульпы используются радиоизотопные плотномеры [Ale93]. Подход имеет ряд недостатков: высокая стоимость оборудования и обслуживания; деградация радиоактивного элемента [Pat16]; невозможность установить плотномер в определённых местах; требуется лицензирование и соблюдение норм радиационной безопасности. Особого внимания требует факт деградации радиоактивного элемента, поскольку он вызывает необходимость его замены. При отсутствии возможности решить вопрос замены приходится сталкиваться с проблемой недостоверных измерений.

Согласно экспертному мнению альтернативным вариантом управления технологическим узлом является расчет соотношения Ж/Т (жидкого к твердому). Для этого необходимо понимать в каких соотношениях происходит смешивание потоков, что вызывает затруднения при сложных технологических схемах предприятия. При отсутствии своевременного обслуживания агрегатов (например, распределительные коробки, грохоты с большим количеством дек) возможно сильное искажение расчетного соотношения Ж/Т.

Также можно проводить расчет плотности пульпы через давление нагнетания насосов и напора. В данном подходе необходим датчик измерения давления и достоверный измеритель расхода пульпы (расходомер), которые требуют регулярного обслуживания поскольку пульпа

забивает датчики, искажая измерения. Влияние пульпы на работу насоса предусматривает корректировку метода, иначе возможен сдвиг рабочих характеристик и снижение точности [Vis23].

Возможные искажения реальных оценок плотности пульпы в каждом из подходов позволили сделать заключение о необходимости построения виртуального анализатора плотности, который был бы более устойчив к деградации и менее затратным по сравнению с физическим плотномером. Это позволит оперативно и с достаточной точностью контролировать течение технологических процессов на предприятии.

Наличие виртуального плотнмера позволит принимать решения заранее, что способствует учету ситуации в технологическом процессе и своевременному управлению им. С использованием плотнмера можно прогнозировать значение плотности пульпы в зависимости от изменения других параметров, а также подобрать их оптимальные значения.

Целью исследования является подбор модели для разработки виртуального анализатора плотности пульпы.

Для достижения поставленной цели были поставлены следующие задачи:

- выбор места для виртуального плотнмера на основе анализа технологического процесса;
- изучения мнемосхем контрольно-измерительных приборов (КИП) и приборов;
- сбор и первичная обработка данных КИП;
- построение базовых моделей и подбор гиперпараметров;
- тестирование моделей в реальных условиях и выбор наиболее перспективной.

МАТЕРИАЛЫ И МЕТОДЫ

По результатам исследования технологического процесса для прогнозирования плотности было выбрано место слива мельницы (рис. 1), так как в данном узле известна выходная плотность продукта из мельницы (за вычетом маточника, подаваемого в бак слива). Все управляемые и значимые параметры находятся до него, что исключает утечку данных. Также это обусловлено тем, что в указанной точке находятся пробоотборники и физический плотномер, с помощью которых на первоначальном этапе можно контролировать работоспособность моделей, а также контролировать течение процесса с помощью рычагов (подача маточного раствора), корректирующих плотность пульпы.

Для построения модели были взяты следующие показатели: объем подаваемой руды на фабрику, т/ч; расход маточного раствора, м³/ч; расход камерного продукта на мельницу, м³/ч; суммарный расход насосов, м³/ч.

Сбор данных и их подготовка

В качестве набора данных использованы данные с контрольно-измерительных приборов с интервалом 1 сек за период 40 дней. Следует отметить следующие аспекты, касающиеся данных.

Из наблюдений были исключены периоды простоя и низкой «нагрузки на фабрику» (обусловлено тем, что при запуске линий после простоя необходимо время, чтобы технологический процесс пришел в норму и можно было без опасений использовать рычаги воздействия на плотность).

Проведена очистка данных по технологическим и регламентным границам. Технологические границы показаний (диапазон значений, которые указаны в паспортах контрольно-измерительных приборов как возможные) определены на основании техрегламента предприятия. Как следствие, из набора данных были удалены ошибки КИП.

Регламентные границы (диапазон значений, который характерен для фабрики в период ее плановой работы) определены на исторических данных о работе предприятия. При проведении очистки были убраны данные, которые являются выбросами и не отображают реального течения технологического процесса.




Рис. 1. Схематичное представление узла

Данные агрегировали до 1 и 5 мин соответственно. Также создан набор данных для прогнозирования будущей плотности на 5 мин вперед, для каждого типа строились различные модели. Размер обучающего и тестового набора данных (для 1 минутной агрегации) составил 32269 и 10757 наблюдений соответственно. Размер обучающего и тестового набора данных (для 5-минутной агрегации) составил 6615 и 2206 наблюдений соответственно. Размер обучающего и тестового набора данных (для прогнозирования на 5 минут вперед) составил 6456 и 2152 наблюдений соответственно.

Базовые модели

В моделях сложные признаки не создавались, так как важным критерием является интерпретируемость. Это принципиально для рассматриваемой задачи из-за необходимости понимать, как и каким образом происходит прогнозирование результатов. Также более простые модели легче интегрировать в АСУТП предприятия, нежели модели со сложными признаками.

В ходе эксперимента и тестирования применялись следующие модели: линейная регрессия (LinearRegression) [Su12]; решающее дерево (DecisionTree) [Son15]; градиентные бустинг (CatBoost) [Pro18]; сети Колмогорова–Арнольда (KAN) [Liu24].

Выбор моделей был обусловлен следующими факторами.

Линейная регрессия и решающее дерево представляют собой базовые модели, позволяющие проверить наличие зависимостей и возможность прогнозирования в целом. В рассматриваемой задаче модели характеризуются интерпретируемостью и простотой понимания.

Градиентный бустинг (в частности, его вариация CatBoost) является одним из классических подходов в решении подобного рода задач, и характеризуется способностью аппроксимировать сложные зависимости;

Сети Колмогорова–Арнольда представляют собой вариацию нейронных сетей, в которой вместо обучения простых линейных весов происходит обучение функции для каждого входного параметра, что позволяет аппроксимировать сложные математические и физические зависимости. Еще одним преимуществом подхода является возможность символизировать формулу, что в свою очередь значительно упрощает понимание работы модели.

Метрики оценки качества модели. Для оценки качества построенных моделей использовались следующие показатели: средняя абсолютная ошибка (MAE); медианная абсолютная

ошибка (MedianAE); коэффициент детерминации (R^2); средняя абсолютная процентная ошибка (MAPE).

Выбор метрик обусловлен следующими факторами: MAE и MedianAE позволяет понять, насколько в абсолютных единицах ошибается модель, что необходимо для понимания производственного процесса; R^2 позволяет понимать, насколько хорошо модель объясняет вариацию целевой переменной, а MAPE используется для сравнения погрешности модели с погрешностью приборов.

Подбор гиперпараметров

Для решающего дерева и градиентного бустинга подбор наиболее подходящих гиперпараметров осуществлялся с помощью фреймворка Optuna [Aki19], который минимизирует/максимизирует целевую функцию. В данном случае подбор осуществлялся с целью максимизации R^2 и минимизации MAE. Для каждой модели было запущено 1000 испытаний, в качестве механизма досрочной остановки неудачных испытаний выбран Hyperband [Li18], а алгоритм подбора оптимальных параметров основан на байесовской оптимизации [Sno12].

При подборе оптимальной архитектуры KAN выбирались следующие параметры путем полного перебора: ширина сети; степень сплайна; размер сетки сплайна.

Решение было реализовано с помощью библиотек: ruKAN, PyTorch, Numpy. Данный выбор был сделан в связи с простотой реализации и возможностью оперативно проверить работоспособность модели на практике.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Для выбора модели, положенной в основу виртуального анализатора плотности пульпы, эксперимент проведен на моделях LinearRegression, DecisionTree, CatBoost, KAN с оценкой качества моделей по метрикам MAE, MedianAE, R^2 , MAPE, которые получены при проведении эксперимента и приведены в таблицах (табл. 1–3). Результаты представлены для различных типов агрегаций, а также для прогноза глубиной 5 мин. Указаны результаты для обучающей и тестовой выборок соответственно.

Таблица 1

Результаты экспериментов, агрегация 1 мин

Модель	R^2		MAE		MedianAE		MAPE	
	Train	Test	Train	Test	Train	Test	Train	Test
LinearRegression	0.36	0.01	34.28	58.69	28.27	51.81	0.02	0.04
DecisionTree	0.56	0.17	28.14	52.72	22.47	44.67	0.02	0.03
CatBoost	0.58	0.28	27.47	48.98	22.07	41.05	0.02	0.03
KAN	0.41	0.33	32.62	46.76	26.22	38.20	0.02	0.03

Таблица 2

Результаты экспериментов, агрегация 5 мин

Модель	r^2		MAE		MedianAE		MAPE	
	Train	Test	Train	Test	Train	Test	Train	Test
LinearRegression	0.42	0.08	32.12	58.18	26.70	51.33	0.02	0.04
DecisionTree	0.73	0.27	21.17	50.70	16.62	44.03	0.01	0.03
CatBoost	0.81	0.32	18.22	48.66	14.22	41.14	0.01	0.03
KAN	0.49	0.45	29.55	41.33	23.78	32.38	0.02	0.03

Таблица 3

Результаты экспериментов, прогноз глубиной 5 минут

Модель	r^2		MAE		MedianAE		MAPE	
	Train	Test	Train	Test	Train	Test	Train	Test
LinearRegression	0.42	-0.01	30.02	56.64	24.94	49.66	0.02	0.04
DesscionTree	0.54	0.05	25.36	54.24	19.27	47.84	0.02	0.04
CatBoost	0.67	0.23	21.95	47.83	17.27	39.45	0.01	0.03
KAN	0.47	0.4	28.05	41.44	22.58	33.68	0.02	0.03

Как видно из полученных результатов, KAN показали себя наилучшим образом на тестовой выборке. При этом стоит отметить, что не возникла проблема сильного переобучения модели, как например, на градиентном бустинге или решающем дереве. Следует обратить внимание на тот факт, что при этом сохранилась интерпретируемость результатов. На рис. 2 отражена аппроксимация функции для 5-минутной агрегации моделью KAN, что делает ее более понятной.




Рис. 2. Вид нейронной сети для 5 минутной агрегации

В библиотеку встроена возможность символизации формулы, с помощью которой можно точно записать формулы, состоящие из чистых функций, а сети как на рис. 2 можно аппроксимировать лишь приблизительно, либо добавив в символические формулы отличные от стандартного набора функции. Для примера выше получается следующая функция:

$$y = 27.57 \cos(0.02 x_1 - 2.0) + 175.35 e^{-0.45(0.01 x_2 - 1)^2} + 0.2(1 - 0.02 x_3)^2 + 0.37 x_4 + 1236.11,$$

где x_1 – маточный раствор, $\text{м}^3/\text{ч}$; x_2 – суммарный расход насосов, $\text{м}^3/\text{ч}$; x_3 – суммарная подача камерного продукта, $\text{м}^3/\text{ч}$; x_4 – объем подаваемой на фабрику руды, $\text{т}/\text{ч}$.

Далее отражено как изменялась функция потерь в зависимости от изменения параметров настройки сети. Для всех экспериментов (за исключением тех, в которых перебирался соответствующий параметр), использовались следующие значения: ширина сети (количество слоев в сети) – 1 входной слой с 5 нейронами, 1 выходной слой с 1 нейроном; число шагов оптимизации – 150; размер сетки сплайна (количество отрезков, на каждом из которых свой полином) – 3; степень сплайна (максимальная степень использованных полиномов) – 2; метрики оптимизации – RMSE.

Ошибка (рис. 3) на начальных этапах стремительно сокращается при увеличении количества шагов, при этом быстро выходит на плато, что характерно для нейронных сетей [Afa20]. Также стоит отметить, что время вычисления увеличивается значительно (с 1 сек до 11 сек) при сравнении с базовым вариантом, что на больших объемах данных или глубокой архитектуре может стать критическим фактором.

По мере увеличения размера сетки сплайна без изменения других параметров (рис. 4) происходит постепенное переобучение модели, при этом степень ее обобщающей способности в конкретной задаче остается на примерно одинаковом уровне.

Степень параметризации сплайна практически не влияет на изменение ошибки на обучающей выборке (рис. 5). При этом на тестовой выборке видно нестабильное поведение, что обуславливает необходимость подбирать степень под каждую конкретную задачу и архитектуру.




Рис. 3. Изменение ошибки в зависимости от количества шагов




Рис. 4. Изменения ошибки в зависимости от размера сетки сплайна




Рис. 5. Изменение ошибки в зависимости от степени параметризации сплайна

При попарном изменении размера сетки сплайна и степени сплайна (рис. 6) наименьшая ошибка в среднем достигается при небольшой размерности сплайна и его степени.




Рис. 6. Изменение ошибки при попарном изменении размера сетки сплайна и степени сплайна

ОБСУЖДЕНИЕ

Рассматривая результаты проведённых экспериментов, можно заключить, что применение KAN в контексте прогнозирования технологических параметров вполне оправдано, дает лучшую точность и имеет более высокую обобщающую способность по сравнению с классическим градиентным бустингом или более простыми линейными моделями, при этом сохраняя интерпретируемость и простоту понимания последних.

Однако ключевой недостаток данного подхода заключается в текущей доступной технологической реализации (а именно библиотеке), так как она имеет ряд существенных недостатков. В частности, выявляются недочеты при воспроизводимости ряда экспериментов даже при фиксировании числа случайной инициализации и прочих равных параметрах. Стоит отметить слабую техническую реализацию, так как для ее стабильной и адекватной работы необходимо регулярно дописывать и переписывать имеющуюся кодовую базу, что в рамках продуктовой разработки накладывает значительные ограничения при применении на практике.

Также для наиболее подходящей модели зачастую не удастся составить понятную символьную формулу, в связи с чем приходится подбирать похожую или самостоятельно добавлять функции для составления последней. Все это накладывает значительные ограничения в практическом применении.

ЗАКЛЮЧЕНИЕ

Согласно цели исследования, направленной на выбор модели для построения виртуального анализатора плотности пульпы, модель KAN по метрикам (MAE, MedianAE, R^2 , MAPE) превзошла остальные модели (LinearRegression, DecisionTree, CatBoost). Однако некоторая нестабильность и невозможность воспроизведения результатов накладывает ограничения на использование текущей реализации. Также выявлены погрешности в символьном представлении модели.

При определенной доработке и увеличении метрик качества моделей предлагаемый подход можно использовать для превентивного управления технологическим узлом, что позволит повысить производительность фабрики и увеличить экономические показатели предприятия, сократив потери от переизмельчения/недоизмельчения продукта в соответствующей стадии технологического процесса.

Следующим шагом исследований предлагается собственная реализация предлагаемого подхода на базе KAN (реализация собственной библиотеки/доработки существующей), либо поиска аналогичных реализаций. Также планируется на базе созданных виртуальных анализаторов реализовать полноценную систему советчик, которая бы в режиме реального времени рекомендовала бы необходимые параметры для управления технологическим узлом предприятия, что согласуется с общероссийским трендом на цифровизацию подобного рода предприятий [Сax22]

БЛАГОДАРНОСТИ И ПОДДЕРЖКА

Автор благодарит руководителя научного проекта д-ра техн. наук, доц. О. Н. Сметанину за консультации в процессе написания статьи.

СПИСОК ЛИТЕРАТУРЫ | REFERENCES

- [Afa20] Afaq S., Rao S. Significance of epochs on training a neural network // Int. J. Sci. Technol. Res. 2020. Vol. 9. No. 06. Pp. 485–488.
- [Aki19] Akiba T. et al. Optuna: A next-generation hyperparameter optimization framework // Proc. 25th ACM SIGKDD international conference on knowledge discovery & data mining. 2019. Pp. 2623–2631. DOI: [10.1145/3292500.3330701](https://doi.org/10.1145/3292500.3330701).
- [Ale93] Alexander E. R. Density measures: A review and analysis // J. Architectural and Planning Research. 1993. Pp. 181–202.
- [Li18] Li L. et al. Hyperband: A novel bandit-based approach to hyperparameter optimization // Journal of Machine Learning Research. 2018. Vol. 18. No. 185. Pp. 1–52.
- [Liu24] Liu Z. et al. Kan: Kolmogorov-arnold networks // arXiv preprint. 2024. DOI: [10.48550/arXiv.2404.19756](https://doi.org/10.48550/arXiv.2404.19756).
- [Pro18] Prokhorenkova L. et al. CatBoost: unbiased boosting with categorical features // Advances in Neural Information Processing Systems. 2018. Vol. 31. DOI: [10.48550/arXiv.1706.09516](https://doi.org/10.48550/arXiv.1706.09516).
- [Sno12] Snoek J., Larochelle H., Adams R. P. Practical bayesian optimization of machine learning algorithms // Advances in Neural Information Processing Systems. 2012. Vol. 25.
- [Son15] Song Y. Y., Lu Y. Decision tree methods: applications for classification and prediction // Shanghai Archives of Psychiatry. 2015. DOI: [10.11919/j.issn.1002-0829.215044](https://doi.org/10.11919/j.issn.1002-0829.215044).
- [Su12] Su X., Yan X., Tsai C. L. Linear regression // Wiley Interdisciplinary Reviews: Computational Statistics. 2012. Vol. 4. No. 3. Pp. 275–294. DOI: [10.1002/wics.1198](https://doi.org/10.1002/wics.1198).
- [Vis23] Visintainer R. et al. Slurry Transport Using Centrifugal Pumps. Berlin/Heidelberg, Germany: Springer, 2023. 432 p. DOI: [10.1007/978-3-031-25440-6](https://doi.org/10.1007/978-3-031-25440-6).
- [Виш12] Вишняк Б. А., Поздеев А. А. О технологии обогащения и автоматизации процессов современной калийной флотационной фабрики // Горный информац.-аналитич. бюллетень. 2012. № 9. С. 138–150. EDN [PYRJQX](https://www.edn.ru/PYRJQX). [Vishnyak B. A., Pozdeev A. A. On beneficiation technology and process automation at a modern potash flotation plant // Mining Informational and Analytical Bulletin. 2012. No. 9. Pp. 138–150. EDN: [PYRJQX](https://www.edn.ru/PYRJQX). (In Russian).]
- [Зат24] Затонский А. В., Беккер В. Ф., Сарамага Ю. О. Управление плотностью питания стержневой барабанной мельницы на стадии измельчения сильвинитовой руды // Горный информац.-аналитич. бюллетень. 2024. № 8. С. 125–140. EDN [WXSVOA](https://www.edn.ru/WXSVOA). [Zatonskiy A. V., Bekker V. F., Saramaga Yu. O. Controlling the feed density of a rod drum mill at the sylvinit ore grinding stage // Mining Informational and Analytical Bulletin. 2024. No. 8. Pp. 125–140. EDN: [WXSVOA](https://www.edn.ru/WXSVOA). (In Russian).]
- [Мат16] Матвеев В. А. Концепция автоматизированного управления калийной флотационной фабрикой // Горный журнал. 2016. № 4. С. 84–87. EDN [WHFTCT](https://www.edn.ru/WHFTCT). [Matveev V. A. A concept for automated control of a potash flotation plant // Gornyi Zhurnal. 2016. No. 4. Pp. 84–87. EDN: [WHFTCT](https://www.edn.ru/WHFTCT). (In Russian).]
- [Пат16] Матвеев В. А., Титков С. Н., Березин М. А. Способ калибровки и проверки радиоизотопных плотномеров суспензий по образцам-имитаторам. Патент № 2602412 С1 РФ, МПК G01N 9/24. EDN [QZCIUV](https://www.edn.ru/QZCIUV). [Matveev V. A., Titkov S. N., Berezin M. A. Method for calibrating and testing radioisotope suspension density meters using simulation samples. RF patent No. 2602412 C1, IPC G01N 9/24. EDN: [QZCIUV](https://www.edn.ru/QZCIUV). (In Russian).]

- [Сax22] Сахаров Е. М., Бергер Р. В., Рыльникова М. В. Комплексная цифровизация, реализуемая при освоении запасов Гремячинского месторождения калийно-магниевых солей // Горная промышленность. 2022. № 5. С. 69–73. EDN [AGIPTP](#). [Sakharov E. M., Berger R. V., Rylnikova M. V. Comprehensive digitalization implemented during development of the Gremyachinskoye deposit of potassium and magnesium salts // Russian Mining Industry. 2022. No. 5. Pp. 69–73. EDN: [AGIPTP](#). (In Russian).]

ОБ АВТОРЕ | ABOUT THE AUTHOR

КОЛОТОВ Михаил Алексеевич

Уфимский университет науки и технологий, Россия.

mi-sha-9@mail.ru ORCID: [0009-0005-5305-0102](#).

Аспирант кафедры вычислительной математики и кибернетики.

KOLOTOV Mikhail Alekseevich

Ufa University of Science and Technology, Russia.

mi-sha-9@mail.ru ORCID: [0009-0005-5305-0102](#).

Postgraduate student, Department of Computational Mathematics and Cybernetics.

МЕТАДАННЫЕ | METADATA

Заглавие: Интерпретируемая модель виртуального анализа параметров технологической среды на основе сетей Колмогорова–Арнольда.

Авторы: Колотов М. А.

Аннотация: Контроль плотности пульпы на горно-обогатительных комбинатах (ГОК) критически важен для управления процессом. Традиционные радиоизотопные плотномеры дороги и требуют лицензирования, а также подвержены деградации, что приводит к недостоверным измерениям и технологическим рискам. В данной работе исследуется вопрос создания точного и надежного виртуального анализатора плотности пульпы на основе машинного обучения, менее подверженного деградации. Гипотеза заключается в том, что алгоритмы, обученные на данных с контрольно-измерительных приборов, могут оценивать плотность пульпы и с помощью них можно предсказывать возможные изменения технологического процесса. Цель исследования — найти более дешевую, безопасную и устойчивую альтернативу.

Ключевые слова: Цифровизация производства; машинное обучение; прогнозирование параметров; измельчение и дробление руды

Язык: Русский.

Статья поступила в редакцию 1 сентября 2026 г.

Title: Interpretable model for the virtual analysis of technical environment parameters based on Kolmogorov–Arnold networks.

Authors: Kolotov M. A.

Slurry density monitoring at mining and processing plants (MPPs) is critical for process control. Traditional radioisotope density meters are expensive and require licensing, and are also susceptible to degradation, leading to unreliable measurements and process risks. This paper explores the development of an accurate and reliable virtual slurry density analyzer based on machine learning that is less susceptible to degradation. The hypothesis is that algorithms trained on instrumentation data can estimate slurry density and, with this data, predict potential process changes. The objective of the study is to find a cheaper, safer, and more sustainable alternative.

Key words: Production digitalization; machine learning; parameter prediction; ore grinding and crushing.

Language: Russian.

The editors received the article on 1 September 2026.