УДК 004.896 DOI: 10.36871/2618-9976.2026.10.006
© Ганявин В.А., Тюмин Д.О., 2026

МЕТОДЫ ИНТЕРПРЕТАЦИИ РЕЗУЛЬТАТОВ ИЗМЕРЕНИЙ НЕЛИНЕЙНЫХ МОДЕЛЕЙ В ПРЕДИКТИВНЫХ СИСТЕМАХ КОНТРОЛЯ ВЫБРОСОВ ЗАГРЯЗНЯЮЩИХ ВЕЩЕСТВ

Василий Александрович Ганявин[1]

[1] *Кандидат технических наук, заместитель руководителя Инжинирингового центра предиктивной аналитики, Научно-исследовательский институт «Центр экологической промышленной политики», Мытищи, Россия, e-mail: v.ganyavin@eipc.center, ORCID: https://orcid.org/0009-0002-6578-4283*

Дмитрий Олегович Тюмин[2]

[2] *Старший инженер Инжинирингового центра предиктивной аналитики, Научно-исследовательский институт «Центр экологической промышленной политики», Мытищи, Россия, e-mail: d.tyumin@eipc.center, ORCID: https://orcid.org/0009-0004-5676-1252*

ИНФОРМАЦИЯ

Ключевые слова:
система автоматического контроля, предиктивная аналитика, промышленная экология, объяснимое машинное обучение, моделирование.

АННОТАЦИЯ

Фундаментальной проблемой предиктивной аналитики является поиск компромисса между интерпретируемостью и точностью математического алгоритма, который используется для поиска скрытых закономерностей в данных. С одной стороны, простые линейные алгоритмы позволяют проследить логику принятия решений и понять, какие входные параметры повлияли на результат. С другой стороны, сложные методы и глубокие нейронные сети («черные ящики») способны выявлять нелинейные зависимости, но менее прозрачны. Объяснимость логики работы и прозрачность внутренних процессов сложного математического алгоритма наиболее актуальны в критически важных сферах государственного регулирования, где цена ошибки крайне высока, в том числе для экологического контроля и учёта выбросов в промышленности. В статье рассмотрены методы интерпретации результатов измерений нелинейных моделей, входящие в измерительные каналы предиктивной системы автоматического контроля выбросов. Показаны основные достоинства и возможности применяемых методов, такие как извлечение скрытых правил и анализ важности параметров в результате измерения модели. Разработана блок-схема алгоритма расчёта характеристик интерпретируемости и проведена качественная оценка работы нелинейной модели на примере измерения массовой концентрации оксидов азота в отходящих дымовых газах при работе парового котла. Извлечённые скрытые математические зависимости и логические правила могут быть сопоставлены с физико-химическими закономерностями технологического процесса, с уравнениями термодинамики и химической кинетикой горения для обеспечения процесса разработки более надёжных, устойчивых и эффективных решений на основе машинного обучения. В дальнейшем полученная информация о работе нелинейной модели может быть использована различными профильными независимыми структурами для экспертного сопровождения процессов при принятии обоснованного решения по применимости или

доработке (дообучения) измерительных каналов предиктивной системы контроля выбросов.

ДЛЯ ЦИТИРОВАНИЯ: *Ганявин В.А., Тюмин Д.О.* Методы интерпретации результатов измерений нелинейных моделей в предиктивных системах контроля выбросов загрязняющих веществ // Мягкие измерения и вычисления. 2026. № 10. Т. 107. С. 58–72; https://doi.org/10.36871/2618-9976.2026.10.006.

METHODS FOR INTERPRETING MEASUREMENT RESULTS FROM NONLINEAR MODELS IN PREDICTIVE POLLUTANT EMISSION MONITORING SYSTEMS

Vasiliy A. Ganyavin[1]

[1] *Candidate of Technical Sciences, Deputy Head of the Engineering Center for Predictive Analytics, Research Institute «Environmental Industrial Policy Centre», Mytishchi, Russia, e-mail: v.ganyavin@eipc.center, ORCID: https://orcid.org/0009-0002-6578-4283*

Dmitry O. Tyumin[2]

[2] *Senior Engineer of the Engineering Center for Predictive Analytics, Research Institute «Environmental Industrial Policy Centre», Mytishchi, Russia, e-mail: d.tyumin@eipc.center, ORCID: https://orcid.org/0009-0004-5676-1252*

ARTICLE INFO

Keywords:
Automatic control system,
Predictive analytics,
Industrial ecology,
Explainable machine learning,
Modeling.

ABSTRACT

The fundamental problem of predictive analytics is finding a trade-off between interpretability and accuracy of the mathematical algorithm used to discover hidden patterns in data. On the one hand, simple linear algorithms make it possible to trace the decision-making logic and understand which input parameters influenced the result. On the other hand, complex methods and deep neural networks («black boxes») are capable of identifying nonlinear dependencies but are less transparent. The explainability of the logic and the transparency of the internal processes of a complex mathematical algorithm are most relevant in critical areas of public regulation, where the cost of error is extremely high, including for environmental control systems and emission accounting in industry. The article discusses methods for interpreting measurement results of nonlinear models included in the measurement channels of a predictive automatic emission control system. The main advantages and capabilities of the methods used are shown, such as extracting hidden rules and analyzing the importance of parameters in the measurement result of the model. A block diagram of the algorithm for calculating interpretability characteristics has been developed, and a qualitative assessment of the nonlinear model's performance has been carried out using the example of measuring the mass concentration of nitrogen oxides in flue gases during the operation of a steam boiler. The extracted hidden mathematical dependencies and logical rules can be compared with the physicochemical patterns of the technological process, with the equations of thermodynamics and the chemical kinetics of combustion to ensure the development of more reliable, robust, and efficient solutions based on machine learning. In the future, the obtained information about the nonlinear model's operation can be used by various independent specialized organizations for

expert support of processes when making informed decisions on the applicability or refinement (retraining) of the measurement channels of the predictive emission control system.

FOR CITATION: *Ganyavin V.A., Tyumin D.O.* (2026) Methods for interpreting measurement results from nonlinear models in predictive pollutant emission monitoring systems. *Soft measurements and computing,* vol. 107, no. 10, pp. 58–72 (In Russ.); https://doi.org/10.36871/2618-9976.2026.10.006.

Введение

Подходы к измерению выбросов загрязняющих веществ промышленных предприятий предусматривают требования по оснащению источников негативного воздействия системами автоматического контроля выбросов (САКВ) [1], в том числе для систем, разработанных на основе принципов предиктивного анализа технологического процесса [2].

На этапе проверки и валидации разработанного алгоритма для предиктивной автоматической измерительной системы (ПАИС) контроля выбросов существенным является способность объяснения (интерпретируемость) результатов измерений, выдаваемые математическими моделями, и сопоставления результатов измерений с физико-химическими закономерностями технологического процесса, с уравнениями термодинамики и химической кинетикой горения для обеспечения разработки более надёжных, устойчивых и эффективных решений на основе машинного обучения. В этой связи в статье для достижения прозрачности и доверия к результатам измерений ставится задача по определению и оценки методов, позволяющие раскрыть логику формирования результатов измерений математического алгоритма.

Ансамблевые методы и глубокие нейронные сети способны выявлять сложные нелинейные зависимости, но менее прозрачны, чем простые линейные алгоритмы. Нелинейные методы часто рассматриваются как «черные ящики», это затрудняет понимание того, как формируются выходные результаты, а также снижает уровень доверия к этим результатам [3]. Как отмечают Доши-Велес и Ким [4], оценка результатов по одному показателю качества, например, средняя абсолютная ошибка (MAE) или коэффициент детерминации (R2), недостаточна для большинства задач – в экологическом предиктивном контроле недостаточно знать текущее значение показателей выбросов и параметров потока отходящего газа, необходимо понимать, почему модель выдала именно этот результат. Эта сложность и неспособность к интерпретации может препятствовать внедрению ПАИС контроля выбросов для сферы государственного экологического регулирования, при котором требуется чёткое понимание зависимостей, лежащих в основе математических моделей.

Интерпретация нелинейных моделей, таких как ансамблевые алгоритмы градиентного бустинга, многослойные нейронные сети и др., входящих в измерительные каналы ПАИС контроля выбросов, может осуществляться за счёт методов объясняемого искусственного интеллекта (Explainable Artificial Intelligence, XAI) [5, 6, 7]. Методы XAI позволяют перевести скрытые математические зависимости между технологическими параметрами и выбросами в физически обоснованные правила. Среди таких методов можно выделить локальную суррогатную модель (LIME), аппроксимирующую поведение сложной модели в окрестностях конкретной точки более простой моделью, например, линейной регрессией [8]. Другой подход основан на значениях Шепли из теории коалиционных игр [9] – метод, который распределяет разницу между значениями вывода модели со средним значением между отдельными входными переменными. На значениях Шепли построен метод SHAP (Shapley Additive exPlanations), предложенный Лунбергом и Ли, который обеспечивает быструю оценку для

древовидных моделей и предоставляет единую основу как для локальных, так и для глобальных объяснений [10]. Применение этих методов в задачах экологического контроля требует специальных процедур исследования, адаптированных к контексту контроля выбросов на промышленных объектах.

В свою очередь, использование методов XAI на этапе разработки математического алгоритма позволит дополнительно выявлять неверно определённые взаимозависимости между технологическими параметрами процесса и показателями выбросов. В случае, если фиксируется ложная корреляция, например, вместо температуры в зоне горения используется косвенный параметр, который коррелирует с температурой только в узком диапазоне режима и теряет связь при изменении состава сырья, то такую модель необходимо дорабатывать (проводить дообучение) или оснащать технологическую установку дополнительной измерительной информацией.

Материалы и методы

Для раскрытия структуры нелинейных моделей применяются методы локального и глобального объяснения. Локальные методы объяснения позволяют интерпретировать конкретное единичное выходное значение модели в данный момент времени.

Метод LIME (Local Interpretable Model-agnostic Explanations) [8] выполняет локальную аппроксимацию нелинейной модели простой линейной функцией в окрестности исследуемой точки данных. LIME генерирует множество выборок (вариаций исходных данных), получает по ним результаты от модели, взвешивает по близости к исходной точке и обучает на них интерпретируемую простую модель (например, линейную регрессию или Lasso) [8]. Это позволяет понять, какие факторы вызвали скачок выбросов NOx или CO. Однако применение LIME в задачах экологического мониторинга представляет сложность: выбор ширины ядра, определяющей окрестность, остаётся нерешённой проблемой, и разные настройки могут давать различные объяснения [11].

Метод SHAP (SHapley Additive exPlanations) [10] основан на расчёте значений Шепли из теории игр [9], что обеспечивает ему фундаментальные математические свойства. Для оценки вклада конкретного параметра SHAP вычисляет разницу в результатах модели с этим параметром и без него для всех возможных подмножеств (комбинаций) остальных параметров. Метод распределяет вклад каждого технологического параметра (температура, расход топлива, давление и т. д.) в итоговое значение результата измерения модели. Значения Шепли являются единственным методом атрибуции, удовлетворяющим свойствам эффективности, симметрии, фиктивности и аддитивности, что даёт ему прочное теоретическое обоснование [9; 10]. Локальная точность гарантирует, что сумма значений Шепли всех входных параметров для конкретного объекта равна разнице между результатом измерения модели для этого объекта и средним ожидаемым результатом измерения. Метод значений Шепли инвариантен к архитектуре модели и строго математически обоснован, что гарантирует, что если модель меняется так, что вклад определённого входного параметра увеличивается или остаётся прежним (независимо от других параметров), то его значение Шепли не может уменьшиться [10].

На рисунке 1 представлена блок-схема приближённого расчёта значений Шепли, измеряющего вклад -го входного параметра в результат измерения модели.

Далее при найденных значениях маржинального вклада по каждому входному параметру получаем выражение вычисления значений Шепли как среднее вкладов [10]:

$$\phi_j(\mathbb{x}) = \frac{1}{N}\sum_{i=1}^{N}\phi_j^{(i)}, \quad (1)$$

где N – количество итераций; $\mathbb{X}$ – матрица входных данных; j – количество параметров в $\mathbb{X}$; m – количество объектов в $\mathbb{X}$; $\mathbb{x} = (x_1, \dots, x_j)$ – исследуемый объект значений входных параметров; $z = (z_1, \dots, z_j)$ – случайный объект значений входных параметров; $z_p = (z_1, \dots z_j, \dots, z_d)$ – объект со случайной перестановкой индексов параметров объекта z; F – математическая модель; ϕ_j – маржинальный вклад по каждому входному параметру.

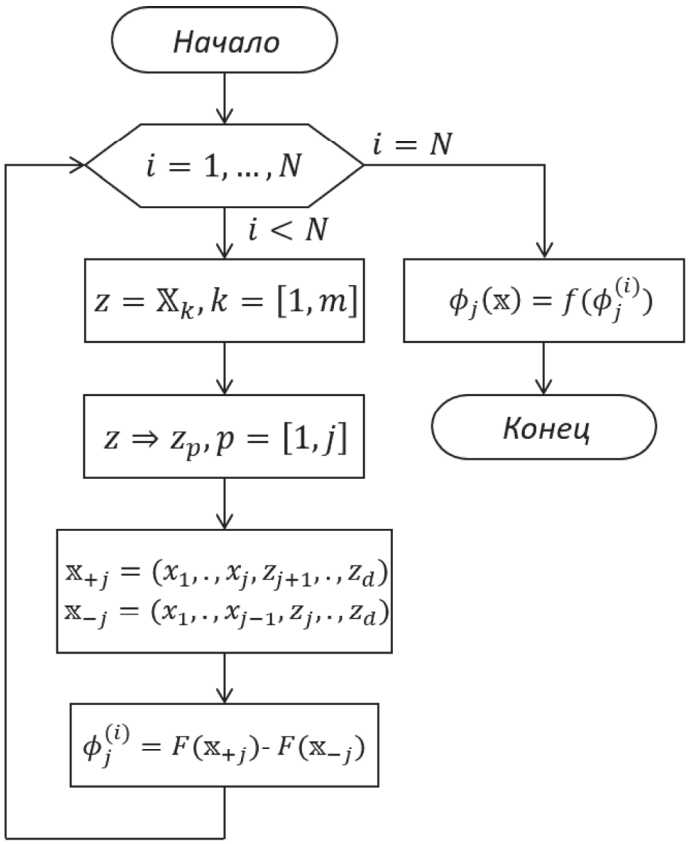


Рис. 1. Блок-схема расчёта значений Шепли

В соответствии с алгоритмом, представленным на рисунке 1, на каждой итерации выполняется следующая процедура: из матрицы входных данных $\mathbb{X}$ случайным образом выбирается объект z; генерируется случайная перестановка индексов параметров; формируются два комбинированных объекта – с j-м параметром из $\mathbb{x}$ (объект $\mathbb{x}_{+j}$) и без него (объект $\mathbb{x}_{-j}$), где значения параметров слева от позиции j в перестановке берутся из $\mathbb{x}$, а справа – из z; вычисляются маржинальный вклад как разность результатов модели для этих двух объектов $\phi_j^{(i)} = F(\mathbb{x}_{+j} - F(\mathbb{x}_{-j})$. После N итераций значение Шепли для -го параметра вычисляется как среднее арифметическое всех маржинальных вкладов по формуле (1). Данный алгоритм соответствует методу Монте-Карло для аппроксимации значений Шепли, предложенный Штрумбелем и Кононенко [12].

Главное достоинство SHAP заключается в строгом математическом обосновании на базе теории игр, гарантирующем справедливое распределение вкладов независимых входных переменных, в то время как преимущество LIME состоит в высокой скорости вычислений и гибкости при работе с текстами и изображениями [13; 14]. Однако SHAP предоставляет единую основу как для локальных, так и для глобальных объяснений, тогда как LIME ограничен локальным уровнем [8]. Глобальные методы объяснения показывают общую логику работы модели на всем диапазоне исторических данных технологического процесса.

Графики частичной зависимости (Partial Dependence Plot, PDP) иллюстрируют маржинальный эффект одного или двух параметров на результат измерения, усредняя влияние остальных параметров. Визуализация позволяет отследить физику процесса (например, подтвердить нелинейный рост оксидов азота при увеличении температуры в топке). В дополнение к PDP могут использоваться графики индивидуальных условий ожиданий (Individual Conditional Expectation, ICE) [11], которые показывают индивидуальные изменения результата измерения для каждого отдельного объекта матрицы входных данных.

Результаты

Известно, что при сжигании топлива в топках котлов происходит выброс в атмосферу загрязняющих веществ: оксида азота (NO_x), оксида углерода (CO) и диоксида серы (SO_2). В качестве объекта моделирования рассматривается двухбарабанный водотрубный паровой котёл среднего давления с естественной циркуляцией, работающий на природном газе и предназначенный для генерации пара, подаваемого на паровые турбины. Топочная камера котла оснащена тремя горелками, размещёнными на вертикальной части основного блока котла.

Генерация пара осуществляется за счёт утилизации тепла дымовых газов, образующихся при сжигании топлива. Образующиеся топочные газы перед сбросом их в атмосферу через дымовую трубу проходят через экономайзер, где охлаждаются питательной водой. Для снижения концентрации оксидов азота (NO_x) в дымовых газах предусмотрена система рециркуляции: часть охлаждённых газов отбирается вентилятором рециркуляции и подмешивается к дутьевому воздуху.

На рисунке 2 приведена упрощённая схема автоматизации оборудования парового котла с указанием основных датчиков, участвующих в контроле и управлении технологическим процессом. Обычно управление паровым котлом строится вокруг поддержания параметров для трёх ключевых систем управления: контур регулирования уровня воды в барабане, контур поддержания давления и температуры пара для турбины, контур регулирования процесса горения в топке котла. Рассмотрим процесс горения как наиболее влияющий на количественное формирование выбросов загрязняющих веществ, который представляет собой две связанные между собой подсистемы управления процессом. Первая подсистема образует каналы подачи топлива – природного газа (ПГ) на основные и вспомогательные горелки котла с контролем расходов за счёт степени открытия / закрытия регулирующих клапанов (FY) – параметры X9, X10 и контролем давления (PI) – параметры X3, X4, X7, X8. Вторая подсистема образует канал подачи воздуха (O_2) за счёт изменения производительности дутьевого вентилятора или степени открытия / закрытия регулирующего клапана (FY) – параметр X11 и температуры воздуха (TI) – параметр X2. Регулирующее устройство (как правило это ПИД-регулятор) поддерживает оптимальное соотношение топливо-воздух для полного сгорания веществ с коррекцией по содержанию кислорода (AI) – параметр X1 в дымовых газах. Регулирование канала подачи части дымовых газов осуществляется за счёт изменения производительности насоса (FIC) – параметр X6 и степени открытия / закрытия регулирующего клапана (FY) – параметр X12.

В ходе обучения математической модели измерения массовой концентрации оксидов азота (NO_x) в отходящих газах наилучшие результаты показала модель CatBoost [15] на 170 деревьях решений. Алгоритмы бустинга, такие как XGBoost и CatBoost, обеспечивают высокую точность результатов измерения благодаря своим эффективным методам регуляризации и робастности [16], в свою очередь Random Forest и Extra Trees обеспечивают снижение переобучения [17]. Алгоритм AdaBoost менее надёжен, но обладает преимуществом при работе с несбалансированными наборами данных [18]. Выбор модели

CatBoost для дальнейшего анализа обусловлен минимальной ошибкой на валидационной выборке, что свидетельствует о том, что построенная нелинейная модель успешно воспроизводит общую динамику и характер изменения концентрации оксидов азота на тестовом наборе данных.

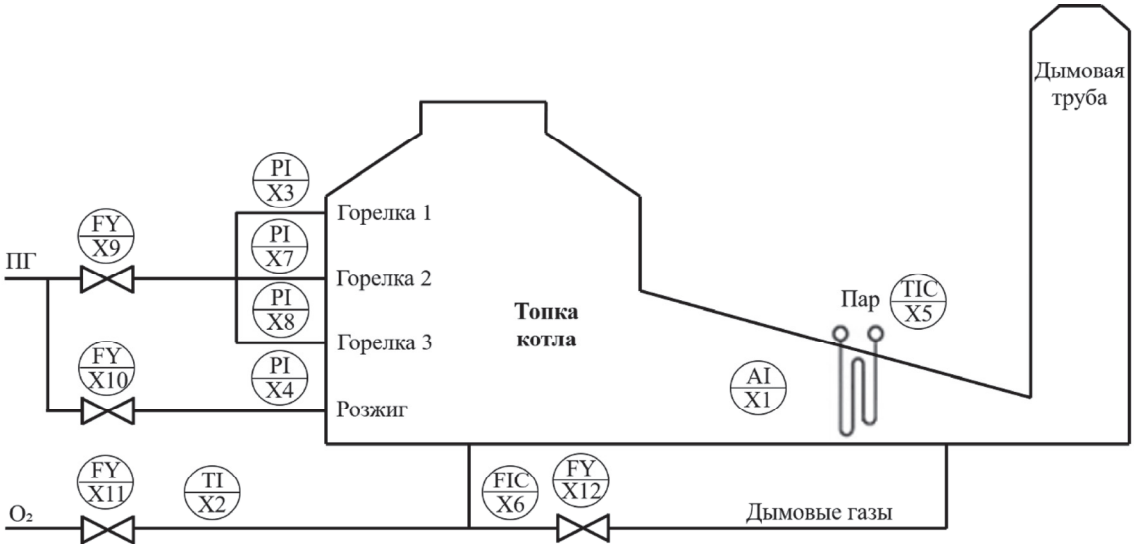


Рис. 2. Упрощённая функциональная схема автоматизации оборудования котла

Обучение выполнялось на массиве данных, содержащего около 400000 последовательных во времени измерений. В качестве входного массива $\mathbb{X} = \{X_1, X_2, \ldots, X_{12}\}$ выступали отобранные ключевые параметры технологического процесса, а выходной переменной являлось значение массовой концентрации NO_x в отходящих газах. Оптимизация гиперпараметров осуществлялась с применением кросс-валидации без процедуры перемешивания данных. Ключевые технологические параметры модели NO_x представлены в таблице 1.

Таблица 1

Ключевые параметры модели NO_x

Схемное обозначение	Название параметра	Ед. изм.
X1	Содержание кислорода в газах топки	% об. д.
X2	Температура воздуха в топку	°C
X3	Давление топливного газа основных горелок 1	МПа
X4	Давление топливного газа вспомогательных горелок	МПа
X5	Температура пара на выходе из турбины	°C
X6	Расход дымовых газов на рециркуляцию	$м^3/ч$
X7	Давление топливного газа основных горелок 2	МПа
X8	Давление топливного газа основных горелок 3	МПа
X9	Клапан подачи газа основным горелкам	%
X10	Клапан подачи газа вспомогательным горелкам	%
X11	Клапан подачи воздуха в топку	%
X12	Клапан подачи дымовых газов на рециркуляцию	%

Проведём процедуру физического объяснения вкладов значений каждого параметра в результат измерения математической модели на основе метода SHAP. Для это-

го из данных тестовой выборки выберем характерные N-серии с разными диапазонами результатов измерений концентрации NO_x:

– Серия N1 при результате измерений модели равным 86 мг/м^3;
– Серия N2 при результате измерений модели равным 152 мг/м^3.

На рисунках 3 и 4 представлены графики силы объяснения SHAP для двух характерных N-серий.

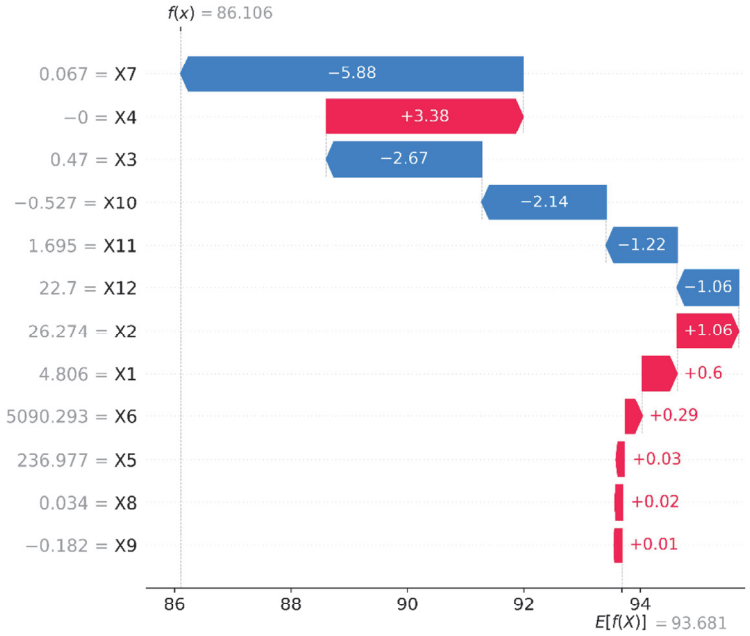


Рис. 3. Оценка влияния параметров на результат модели для серии N1

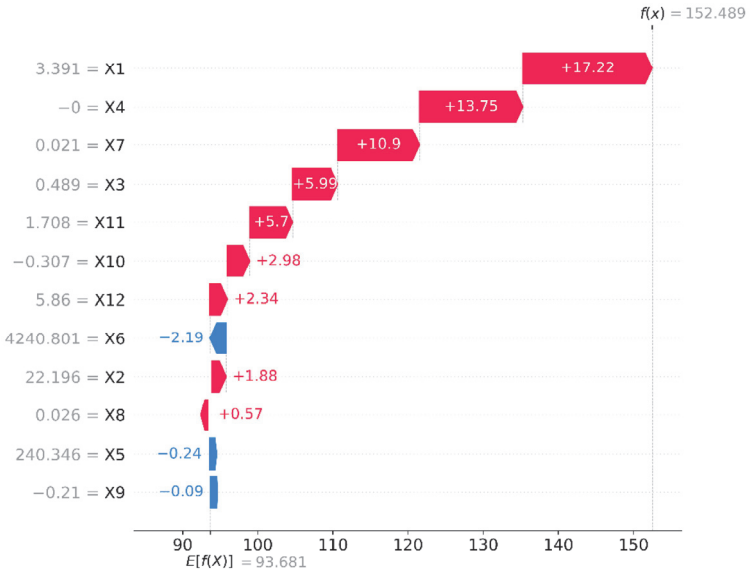


Рис. 4. Оценка влияния параметров на результат модели для серии N2

По результатам сравнения и анализа силы объяснения SHAP двух N-серий видно, что высокие значения концентраций NO_x при практически одинаковых нормах технологического процесса в большей степени обеспечивается тем, что в 3,8 раза уменьшается степень открытия клапана подачи дымовых газов на рециркуляцию (X12) и соответственно уменьшается расход дымовых газов на рециркуляцию (X6). Несколько повышенное содержание

кислорода в газах топки (X1) для серии N1 по сравнению с серией N2 связано с влиянием балластных газов, а не с подачей воздуха в топку (X11). Механизм рециркуляции дымовых газов снижает выбросы NO_x за счёт подачи части охлаждённых продуктов сгорания – инертных компонентов (CO_2, H_2O, N_2), обладающих высокой теплоёмкостью, – обратно в зону горения, что понижает пиковую температуру и уменьшает концентрацию кислорода.

Далее рассмотрим результаты эффектов взаимодействия параметров друг с другом на результат измерения модели. На рисунках 5 и 6 показаны совместное влияние давления топливного газа (X8) и температуры пара на выходе из турбины (X5) на результат модели для двух N-серий.

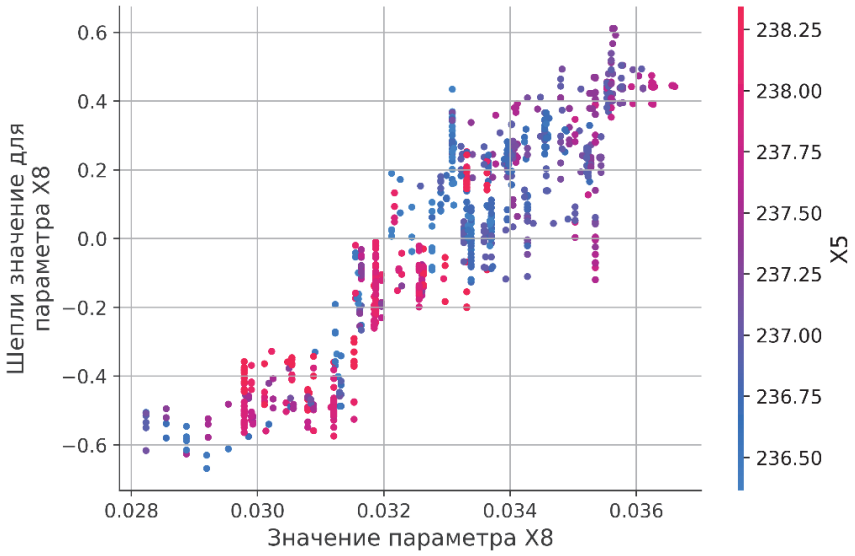


Рис. 5. Совместное влияние давления топливного газа (X8) и температуры пара на выходе из турбины (X5) на результат модели для серии N1

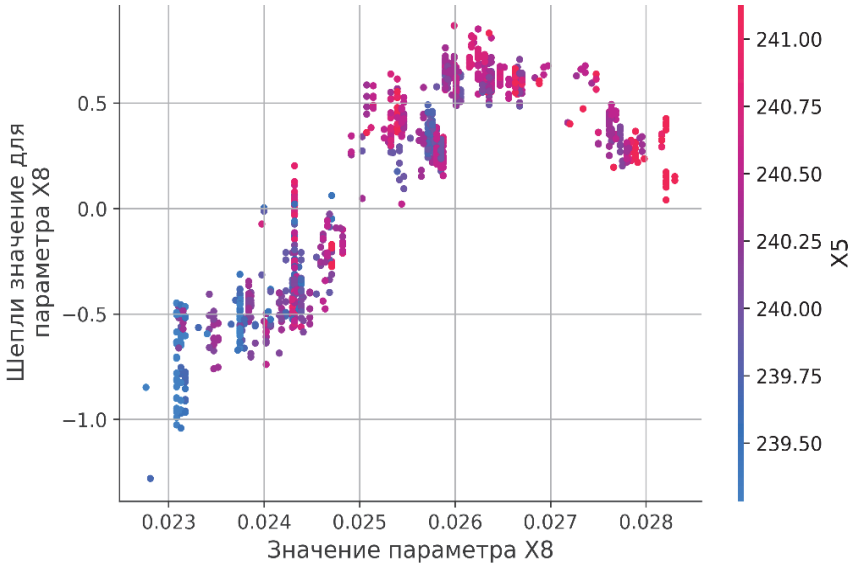


Рис. 6. Совместное влияние давления топливного газа (X8) и температуры пара на выходе из турбины (X5) на результат модели для серии N2

На рисунках 7–10 показаны совместное влияние давления топливного газа (X8) и содержание кислорода (X1) с учётом расхода дымовых газов на рециркуляцию (X6) на результат модели для двух N-серий.

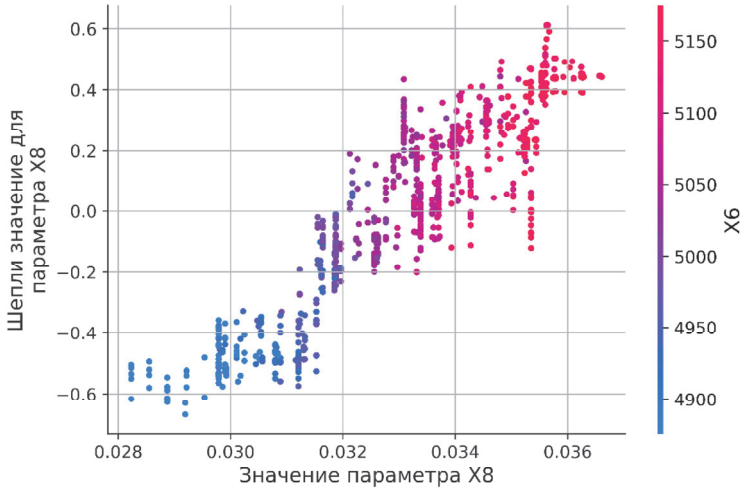


Рис. 7. Совместное влияние давления топливного газа (X8) и расхода дымовых газов на рециркуляцию (X6) на результат модели для серии N1

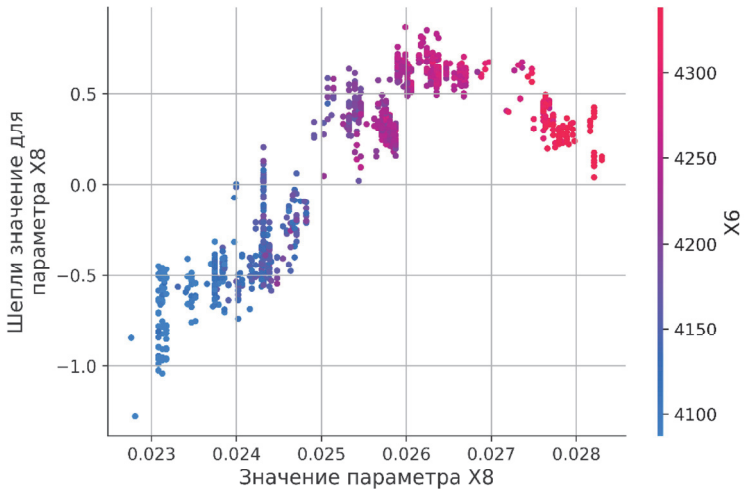


Рис. 8. Совместное влияние давления топливного газа (X8) и расхода дымовых газов на рециркуляцию (X6) на результат модели для серии N2

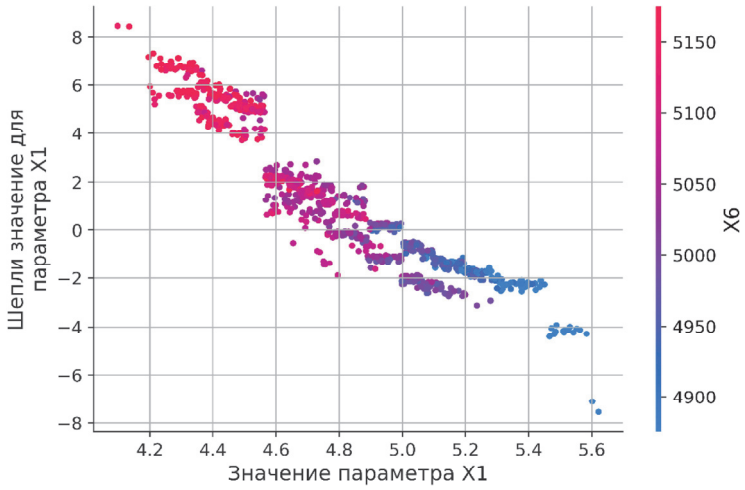


Рис. 9. Совместное влияние содержание кислорода в газах топки (X1) и расхода дымовых газов на рециркуляцию (X6) на результат модели для серии N1

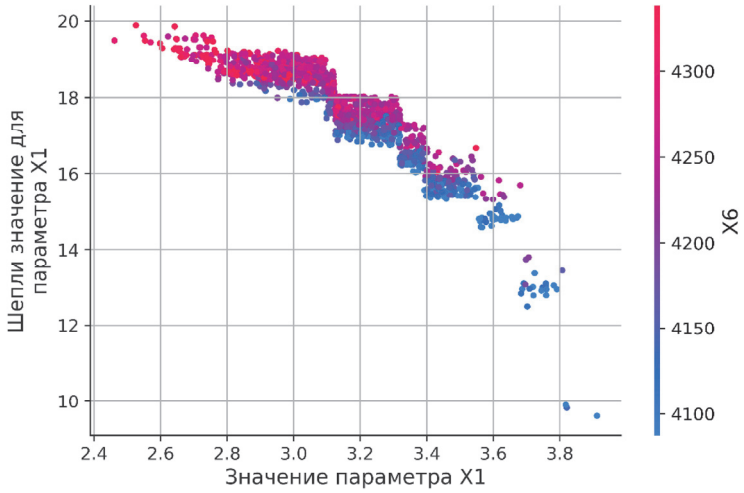


Рис. 10. Совместное влияние содержание кислорода в газах топки (X1) и расхода дымовых газов на рециркуляцию (X6) на результат модели для серии N2

На приведённых выше результатах иллюстрируется, что при увеличении давления топливного газа (X8) увеличивается температура пара на выходе из турбины (X5), а также расход дымовых газов на рециркуляцию (X6). Такое сильное взаимодействие параметров может объясняться жёсткой логикой системы управления, реализованной в ПИД-регуляторах программируемого логического контроллера. Увеличение расхода дымовых газов на рециркуляцию (X6) связано с увеличением нагрузки на выработку пара для турбины, при этом наиболее сильное влияние наблюдается для серии N2 при результате измерений модели, равном 152 мг/м^3.

Наиболее интересные результаты показывают влияние друг на друга содержание кислорода в газах топки (X1) и расход дымовых газов на рециркуляцию (X6). Можно заметить, что при увеличении расхода добавление балластных газов снижает концентрацию кислорода в зоне реакции, при этом для серии N2 вероятность наибольшего снижения кислорода до 2,5% об. д. отражается в наиболее сильном положительном влиянии параметра на результат измерения модели. Уменьшение концентрации кислорода при включении и увеличении рециркуляции дымовых газов обусловлено изменением аэродинамики топочного процесса и балластировкой факела. В зависимости от режима работы котла снижение концентрации кислорода в топке происходит из-за ввода инертных газов. Дымовые газы содержат мало кислорода и много углекислого газа и азота. Сильнее разбавляя входящий воздух, поступающий в топку этой смесью, снижается процентное содержание кислорода в зоне горения, что замедляет химические реакции и снижает температуру факела. Однако если при снижении уровня кислорода из-за ввода рециркуляции растёт NO_x, это является аномалией, вызванной конкретными режимными факторами. В нашем случае при отсутствии рециркуляции дымовых газов концентрация NO_x была бы ещё выше.

Обсуждение

В ходе проведения процедуры физического объяснения вкладов значений каждого параметра в результат измерения математической модели массовой концентрации оксидов азота при работе парового котла были выявлены скрытые математические зависимости и логические правила. Для разных значений диапазонов массовой концентрации идентифицированы правила (законы) управления, заложенные в систему автоматического регулирования технологическим процессом, обеспечивающие безопасность производства, точность регулирования и поддержание технологических параметров в заданных рабочих диапазонах согласно технологическому регламенту.

Получившиеся результаты анализа подтвердили соответствие в поведении ключевых технологических параметров, описанных нелинейной моделью, закономерностям изменения физико-химических свойств газа в топке котла и последующего изменения значений массовой концентрации оксидов азота в отходящих дымовых газах.

Выявленная структура важности параметров позволяет не только объяснить текущие результаты измерений модели, но и использовать её для диагностики состояния измерительного или технологического оборудования. Например, изменение вклада температуры в зоне горения (X5) при неизменных условиях параметров процесса управления может указывать на возникновение систематической погрешности измерений термопары или изменение теплопроводности футеровки, что делает SHAP-анализ потенциальным инструментом для построения систем раннего обнаружения аномалий.

Применённый подход показал свою эффективность для валидации нелинейных моделей в задачах экологического контроля: SHAP-анализ подтверждает физическую обоснованность модели и позволяет верифицировать математические зависимости.

Заключение

В статье рассмотрены методы интерпретации результатов измерений нелинейных моделей, входящие в измерительные каналы предиктивной системы автоматического контроля выбросов. Показаны основные достоинства и возможности применяемых методов, такие как извлечение скрытых правил и анализ важности параметров в результат измерения модели.

Применение рассматриваемых методов интерпретации нелинейных моделей позволит различными профильными независимыми структурами более точно проследить логику принятия решений и обосновать результаты измерений, выдаваемых предиктивными моделями. Вывод может быть использован при экспертном сопровождении процессов принятия обоснованного решения по применимости или доработке алгоритмов моделей для предиктивных систем контроля выбросов.

Список источников

[1] *Стороженко П.А., Скобелев Д.О., Малявин А.С., Костылева В.М., Попов А.Ю.* Международный и российский опыт нормативно-правового регулирования применения систем автоматического контроля выбросов загрязняющих веществ промышленных предприятий // Экология и промышленность России. – 2022. – Т. 26, № 4. – С. 37–43. – DOI: 10.18412/1816-0395-2022-4-37-43. – EDN QZLBGR.

[2] *Скобелев Д.О., Попов А.Ю., Ганявин В.А., Костылева В.М., Малявин А.С.* Подходы к построению предиктивных систем контроля выбросов для современных промышленных технологических процессов // Модели, системы, сети в экономике, технике, природе и обществе. – 2025. – № 3 (55). – С. 46–64. – DOI: 10.21685/2227-8486-2025-3-4. – EDN YEWPNN.

[3] *Medvedevskikh S.V., Aronov P.M., Firsanov V.A.* Covariances in the variance of integral estimates of the contents of components of the substances composition in industrial quantities // Journal of Physics: Conference Series. – 2022. – Vol. 2192. – Pp. 1–5. – DOI: 10.1088/1742-6596/2192/1/012026. – EDN NZLNNU.

[4] *Doshi-Velez F., Kim B.* Towards A Rigorous Science of Interpretable Machine Learning // Statistics. Machine Learning (arXiv). – 2017. – DOI: 10.48550/arXiv.1702.08608.

[5] *Hassija V. et al.* Interpreting Black-Box models: A review on explainable artificial intelligence // Cognitive Computation. – 2023. – Vol. 16, No. 3. – Pp. 45–74. – DOI: 10.1007/s12559-023-10179-8. – EDN XLBLRD.

[6] *Zhou W., Yan Z., Zhang L.* A comparative study of 11 non-linear regression models highlighting autoencoder, DBN, and SVR, enhanced by SHAP importance analysis in soybean

branching prediction // Scientific Reports. – 2024. – Vol. 14, No. 1. – DOI: 10.1038/s41598-024-55243-x. – EDN ZPIFTY.
[7] *Chu W. et al.* SHAP-powered insights into Spatiotemporal effects: unlocking explainable Bayesian-neural-network urban flood forecasting // International Journal of Applied Earth Observation and Geoinformation. – 2024. – Vol. 131. – Art. 103972. – DOI: 10.1016/j.jag.2024.103972. – EDN BDSDDW.
[8] *Ribeiro M.T., Singh S., Guestrin C.* "Why Should I Trust You?": Explaining the Predictions of Any Classifier // In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – 2016. – Pp. 1135–1144. – DOI: 10.48550/arXiv.1602.04938.
[9] *Shapley L.S.* A Value for n-Person Games // In Contributions to the Theory of Games. – Vol. 2. – 1953. – Pp. 307–317. – DOI: 10.1515/9781400881970-018.
[10] *Lundberg S.M., Lee S.-I.* A Unified Approach to Interpreting Model Predictions // In Advances in Neural Information Processing Systems 30 (NIPS 2017). – 2017. – DOI: 10.48550/arXiv.1705.07874.
[11] *Molnar C.* Interpretable Machine Learning: A Guide for Making Black Box Models Explainable. – Leanpub, 2022. – P. 368.
[12] *Strumbelj E., Kononenko I.* Explaining prediction models and individual predictions with feature contributions // Knowledge and Information Systems. – 2013. – Vol. 41, No. 3. – Pp. 647–665. – DOI: 10.1007/s10115-013-0679-x. – EDN NNZUCY.
[13] *Хитрых М.С., Перетягин Н.А., Котякова В.А.* Методы повышения интерпретируемости моделей NLP для критически важных приложений // Парадигма. – 2025. – № 7. – С. 258–265. – EDN WCFDPH.
[14] *Sundararajan M., Najmi A.* The many Shapley values for model explanation // In Proceedings of the 37th International Conference on Machine Learning (ICML 2019). – 2019. – DOI: 10.48550/arXiv.1908.08474.
[15] *Prokhorenkova L., Gusev G., Vorobev A., Dorogush A., Gulin A.* CatBoost: unbiased boosting with categorical features // Advances in Neural Information Processing Systems 31 (NeurIPS 2018). – 2018. – Pp. 6638–6648. – DOI: 10.48550/arXiv.1706.09516. – EDN NRYEVS.
[16] *Jailani N., Mara G.C.M.A.K.* Feature Selection in Ozone Feature Space Impacts Performance in Gradient Boosting, Random Forest, Xgboost and Adaptive Boosting Regressors // International Conference on Current Trends in Advanced Computing (ICCTAC). – 2024. – Pp. 1–6. – DOI: 10.1109/ICCTAC61556.2024.10581262.
[17] *Pellegrino E. et al.* Machine learning random forest for predicting oncosomatic variant NGS analysis // Scientific Reports. – 2021. – Vol. 11. – Art. 21820. – DOI: 10.1038/s41598-021-01253-y. – EDN TZGXTW.
[18] *Attou H., Guezzaz A., Benkirane S., Azrour M.* A new secure model for cloud environments using RBFNN and AdaBoost // SN Computer Science. – 2025. – Vol. 6. – Art. 188. – DOI: 10.1007/s42979-025-03691-1. – EDN ZCFHPB.

References

[1] *Storozhenko P.A., Skobelev D.O., Malyavin A.S., Kostyleva V.M., Popov A.Yu.* 2022. Mezhdunarodnyy i rossiyskiy opyt normativno-pravovogo regulirovaniya primeneniya sistem avtomaticheskogo kontrolya vybrosov zagryaznyayushchikh veshchestv promyshlennykh predpriyatiy [International and Russian experience of legal regulation of the use of automatic emission control systems at industrial enterprises]. Ekologiya i promyshlennost Rossii [Ecology and Industry of Russia], vol. 26, no. 4, pp. 37–43. DOI: 10.18412/1816-0395-2022-4-37-43. EDN QZLBGR.
[2] *Skobelev D.O., Popov A. Yu., Ganyavin V.A., Kostyleva V.M., Malyavin A.S.* 2025. Podkhody k postroeniyu prediktivnykh sistem kontrolya vybrosov dlya sovremennykh promyshlen-

nykh tekhnologicheskikh protsessov [Approaches to building predictive emission control systems for modern industrial technological processes]. Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve [Models, Systems, Networks in Economics, Technology, Nature and Society], no. 3(55), pp. 46–64. DOI: 10.21685/2227-8486-2025-3-4. EDN YEWPNN.

[3] *Medvedevskikh S.V., Aronov P.M., Firsanov V.A.* 2022. Covariances in the variance of integral estimates of the contents of components of the substances composition in industrial quantities. Journal of Physics: Conference Series, vol. 2192, pp. 1–5. DOI: 10.1088/1742-6596/2192/1/012026. EDN NZLNNU.

[4] *Doshi-Velez F., Kim B.* 2017. Towards A Rigorous Science of Interpretable Machine Learning. Statistics. Machine Learning (arXiv). DOI: 10.48550/arXiv.1702.08608.

[5] *Hassija V. et al.* 2023. Interpreting Black-Box models: A review on explainable artificial intelligence. Cognitive Computation, vol. 16, no. 3, pp. 45–74. DOI: 10.1007/s12559-023-10179-8. EDN XLBLRD.

[6] *Zhou W., Yan Z., Zhang L.* 2024. A comparative study of 11 non-linear regression models highlighting autoencoder, DBN, and SVR, enhanced by SHAP importance analysis in soybean branching prediction. Scientific Reports, vol. 14, no. 1. DOI: 10.1038/s41598-024-55243-x. EDN ZPIFTY.

[7] *Chu W. et al.* 2024. SHAP-powered insights into Spatiotemporal effects: unlocking explainable Bayesian-neural-network urban flood forecasting. International Journal of Applied Earth Observation and Geoinformation, vol. 131, 103972. DOI: 10.1016/j.jag.2024.103972. EDN BDSDDW.

[8] *Ribeiro M.T., Singh S., Guestrin C.* 2016. "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 1135–1144. DOI: 10.48550/arXiv.1602.04938.

[9] *Shapley L.S.* 1953. A Value for n-Person Games. In: Contributions to the Theory of Games, vol. 2, pp. 307–317. DOI: 10.1515/9781400881970-018.

[10] *Lundberg S.M., Lee S.-I.* 2017. A Unified Approach to Interpreting Model Predictions. In: Advances in Neural Information Processing Systems 30 (NIPS 2017). DOI: 10.48550/arXiv.1705.07874.

[11] *Molnar C.* 2022. Interpretable Machine Learning: A Guide for Making Black Box Models Explainable. Leanpub.

[12] *Strumbelj E., Kononenko I.* 2013. Explaining prediction models and individual predictions with feature contributions. Knowledge and Information Systems, vol. 41, no. 3, pp. 647–665. DOI: 10.1007/s10115-013-0679-x. EDN NNZUCY.

[13] *Khitrykh M.S., Peretyagin N.A., Kotyakova V.A.* 2025. Metody povysheniya interpretiruemosti modeley NLP dlya kriticheski vazhnykh prilozheniy [Methods for improving the interpretability of NLP models for mission-critical applications]. Paradigma [Paradigm], no. 7, pp. 258–265. EDN WCFDPH.

[14] *Sundararajan M., Najmi A.* 2019. The many Shapley values for model explanation. In: Proceedings of the 37th International Conference on Machine Learning (ICML 2019). DOI: 10.48550/arXiv.1908.08474.

[15] *Prokhorenkova L., Gusev G., Vorobev A., Dorogush A., Gulin A.* 2018. CatBoost: unbiased boosting with categorical features. In: Advances in Neural Information Processing Systems 31 (NeurIPS 2018), pp. 6638–6648. DOI: 10.48550/arXiv.1706.09516. EDN NRYEVS.

[16] *Jailani N., Mara G.C.M.A.K.* 2024. Feature Selection in Ozone Feature Space Impacts Performance in Gradient Boosting, Random Forest, Xgboost and Adaptive Boosting Regressors. In: International Conference on Current Trends in Advanced Computing (ICCTAC), pp. 1–6. DOI: 10.1109/ICCTAC61556.2024.10581262.

[17] *Pellegrino E. et al.* 2021. Machine learning random forest for predicting oncosomatic variant NGS analysis. Scientific Reports, vol. 11, art. 21820. DOI: 10.1038/s41598-021-01253-y. EDN TZGXTW.

[18] *Attou H., Guezzaz A., Benkirane S., Azrour M.* 2025. A new secure model for cloud environments using RBFNN and AdaBoost. SN Computer Science, vol. 6, 188. DOI: 10.1007/s42979-025-03691-1. EDN ZCFHPB.

Вклад авторов: В.А. ГАНЯВИН – научное руководство; концепция исследования; развитие методологии; участие в разработке алгоритмов и методов, и их реализации; написание исходного текста; итоговые выводы;

Д.О. ТЮМИН – участие в разработке алгоритмов и методов, и их реализации; доработка текста; итоговые выводы.

Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: V.A. GANYAVIN – scientific management; research concept; methodology development; participation in development and their implementation; writing the draft; final conclusions;

D.O. TYUMIN – participation in development and their implementation; follow-on revision of the text; final conclusions.

The authors declare no conflicts of interests.

Статья поступила в редакцию 12.10.2026; одобрена после рецензирования 20.10.2026; принята к публикации 23.10.2026.

The article was submitted 12.10.2026; approved after reviewing 20.10.2026; accepted for publication 23.10.2026.
