

Predictive Maintenance Model for Planning Centrifugal Compressor Service Intervals

Goncharov R.A., Taukeev B.B., Kartashov S.V., Kozhukhov Y.V.

ITMO University

Saint-Petersburg, Russian Federation

Abstract. This paper presents a predictive methodology for assessing the technical condition of the first stage of an industrial centrifugal compressor to optimize maintenance intervals. The approach integrates computational fluid dynamics (CFD) modelling of gas-dynamic processes within the flow path with machine learning algorithms to predict the decrease in isentropic efficiency caused by surface degradation due to increasing roughness. Numerical simulations were carried out in ANSYS CFX using a verified digital model based on the NZL design methodology, with deviations of key parameters not exceeding 1.5%. This ensured high physical fidelity and enabled the generation of synthetic training datasets. A total of 61 simulations were conducted with varying equivalent sand roughness values to emulate operational degradation corresponding to up to 13 months of service. Five forecasting models of different complexity were applied: exponential-linear regression, polynomial regression with Ridge regularization, Random Forest, Gaussian Process Regression (GPR), and XGBRegressor. Comparative analysis showed that the exponential-linear regression achieved the highest accuracy (R^2 up to 0.9995) and minimal divergence between training and test datasets (<0.002). Ridge regression on polynomial features demonstrated comparable performance (R^2 up to 0.9950), providing a balance between interpretability and accuracy. The proposed method combines CFD-based surface roughness simulation, synthetic data generation, and machine learning-based prediction of efficiency degradation. A distinctive feature of the approach is modelling degradation through equivalent sand roughness, reflecting the cumulative effect of surface wear and deposit accumulation. The results provide a foundation for developing intelligent predictive maintenance systems for centrifugal compressors, enhancing reliability, operational stability, and energy efficiency.

Keywords: centrifugal compressor, machine learning, CFD modelling, surface roughness, Ridge regression, Gaussian Process Regression, XGBRegressor, predictive maintenance, synthetic data.

DOI: <https://doi.org/10.52254/1857-0070.2025.4-68.13>

UDC:621.515

Model de mentenanță predictivă pentru planificarea intervalelor de service ale compresoarelor centrifuge

Goncharov R.A., Taukeev B.B., Kartashov S.V., Kozhukhov Y.V.

Universitatea ITMO, Saint-Petersburg, Federatia Rusă

Rezumat. Această lucrare prezintă o metodologie predictivă pentru evaluarea stării tehnice a primei etape a unui compresor centrifugal industrial pentru a optimiza intervalele de întreținere. Abordarea integrează modelarea dinamică a fluidelor computaționale (CFD) a proceselor gazodinamice din cadrul traseului de curgere cu algoritmi de învățare automată pentru a prezice scăderea eficienței izentropice cauzată de degradarea suprafeței din cauza creșterii rugozității. Simulările numerice au fost efectuate în ANSYS CFX utilizând un model digital verificat bazat pe metodologia de proiectare NZL, cu abateri ale parametrilor cheie care nu depășesc 1,5%. Acest lucru a asigurat o fidelitate fizică ridicată și a permis generarea de seturi de date de antrenament sintetice. Un total de 61 de simulări au fost efectuate cu valori variabile ale rugozității nisipului echivalent pentru a emula degradarea operațională corespunzătoare unui interval de până la 13 luni de funcționare. Au fost aplicate cinci modele de prognoză de complexitate diferită: regresie liniară exponențială, regresie polinomială cu regularizare Ridge, Random Forest, regresie Gaussian Process (GPR) și XGBRegressor. Analiza comparativă a arătat că regresia liniară exponențială a atins cea mai mare precizie (R^2 până la 0,9995) și o divergență minimă între seturile de date de antrenament și cele de testare ($<0,002$). Regresia pe ridge-uri pe caracteristicile polinomiale a demonstrat performanțe comparabile (R^2 până la 0,9950), oferind un echilibru între interpretabilitate și precizie. Rezultatele oferă o bază pentru dezvoltarea de sisteme inteligente de mentenanță predictivă pentru compresoarele centrifuge, sporind fiabilitatea, stabilitatea operațională și eficiența energetică.

Cuvinte-cheie: compresor centrifugal, învățare automată, modelare CFD, rugozitate suprafață, regresie de creste, regresie de proces gaussiană, XGBRegressor, mentenanță predictivă, date sintetice.

© Кожухов Ю.В., Карташов С.В.,
Гончаров Р.А., Таукеев Б.Б. 2025

Прогнозная модель технического состояния при планировании периодичности технического обслуживания для центробежных компрессоров

Гончаров Р.А., Таукеев Б.Б., Карташов С.В., Кожухов Ю.В.

Университет ИТМО, Санкт-Петербург, Российская Федерация

Аннотация. В статье представлено исследование методов прогнозирования технического состояния первой ступени центробежного компрессора промышленного назначения, направленное на оптимизацию периодичности технического обслуживания. Основной акцент сделан на интеграции численного моделирования газодинамических процессов в проточной части и методов машинного обучения для прогнозирования падения адиабатического КПД при деградации поверхностей вследствие роста шероховатости. Такой подход обеспечивает комплексную оценку влияния эксплуатационного износа на энергетическую эффективность оборудования. Для численного моделирования использовалась среда ANSYS CFX. Верификация по проектной методике НЗЛ показала высокую достоверность модели (отклонения параметров не более 1.5%), что позволило сформировать синтетические обучающие выборки. Серия расчётов с различными значениями эквивалентной шероховатости поверхности имитировала эксплуатационную деградацию и обеспечила построение временных рядов рабочих параметров ступени компрессора. Проведено 61 численных экспериментов при различной шероховатости поверхности проточной части, охватывающих временной диапазон деградации до 13 месяцев эксплуатации. Для прогнозирования применены пять моделей различного уровня сложности: экспоненциально-линейная регрессия, полиномиальная регрессия с регуляризацией Ridge, ансамблевая модель Random Forest, вероятностная Gaussian Process Regression (GPR) и XGBRegressor. Сравнительный анализ продемонстрировал, что наилучшие результаты показала комбинированная экспоненциально-линейная регрессия с коэффициентом детерминации R^2 до 0.9995 и минимальным разрывом между обучающей и тестовой выборками менее 0.002. Второе место по точности заняла Ridge-регрессия на полиномиальных признаках (R^2 до 0.9950), обеспечившая оптимальный баланс между физической интерпретируемостью и точностью прогнозирования. Разработанный подход объединяет CFD-моделирование потока с учетом шероховатости, синтетическое формирование данных и машинное прогнозирование деградации КПД. Особенностью методики является моделирование деградации через эквивалентную песочную шероховатость, учитывающую комплексное влияние накопления отложений. Полученные результаты создают основу для внедрения интеллектуальных систем предиктивного обслуживания центробежных компрессоров, повышая их надёжность и энергетическую эффективность.

Ключевые слова: центробежный компрессор, машинное обучение, CFD-моделирование, шероховатость, Ridge-регрессия, Gaussian Process Regression, XGBRegressor, предиктивное обслуживание, синтетические данные.

ВВЕДЕНИЕ

Центробежные компрессоры являются неотъемлемой частью холодильных и криогенных установок, газотранспортных и энергетических систем, а также широко применяются в нефтегазовой отрасли. От их надежности зависит бесперебойность и эффективность функционирования ключевых технологических объектов — от холодильных и криогенных установок, объектов подготовки и переработки природного газа, включая комплексы по его сжижению и транспортировке до компрессорных станций магистральных газопроводов.

Технологические режимы эксплуатации центробежных компрессоров характеризуются высокими давлениями, переменной нагрузкой и воздействием агрессивных сред, что приводит к ускоренной деградации проточной части и снижению энергетической эффективности. В этих условиях становится особенно актуальным переход от традиционного регламентного

обслуживания к его синтезу с интеллектуальным методом прогнозирования технического состояния и планирования ремонтов.

По данным открытых источников за последние годы отмечается значительный рост интереса к предиктивному обслуживанию (*Predictive Maintenance, PdM*), основанному на анализе больших данных и методах искусственного интеллекта. Исследования показывают, что использование нейронных сетей, в частности *LSTM* и *GRU*, а также специализированных архитектур глубокого обучения, позволяет с высокой точностью прогнозировать остаточный ресурс (*RUL*) турбомашин [1–2]. Дополнительно развивается направление обучения, обеспечивающего возможность построения прогностических моделей при сохранении распределённости данных и соблюдении требований информационной безопасности [3]. Для авиационных ГТД и энергетических ГТУ предложены подходы, использующие новые структуры сетей, включая *Echo State*

Networks и комбинированные *CNN/LSTM*-модели, которые демонстрируют превосходство по метрикам точности и устойчивости [4, 5, 6].

В нефтегазовой отрасли активно разрабатываются специализированные цифровые инструменты для оптимизации обслуживания насосов и компрессоров, сочетающие методы оценки среднего времени наработки на отказ, прогнозирования остаточного ресурса и экспертных правил [7]. Экспериментальные исследования подтверждают эффективность внедрения предиктивных моделей на промышленных компрессорах: применение методов машинного обучения к данным компрессора TA-48 показало возможность раннего прогнозирования отказов и визуализации *RUL* в реальном времени [8]. Важное направление связано с внедрением интеллектуальных сенсоров и IoT-платформ для мониторинга вибрационных и температурных параметров. Такие решения позволяют диагностировать кавитацию в насосах, износ подшипников и другие дефекты с точностью более 85% [9].

В параллельных исследованиях особое внимание уделяется повышению точности численных моделей. Методы локальной корректировки *CFD*-симуляций с применением нейронных сетей позволяют существенно сократить вычислительные затраты и повысить точность расчётов [10]. Для компрессоров и турбин предложены диагностические подходы на основе спектрального анализа вибрационных сигналов, что обеспечивает переход от планового к предиктивному обслуживанию и подтверждается результатами ремонта турбокомпрессоров [11]. Кроме того, активно исследуется интеграция методов машинного обучения в задачи вычислительной газодинамики, включая моделирование переходных процессов течения и отрывных структур в низконапорных турбинах [12]. Эти разработки формируют основу для построения цифровых двойников, способных не только воспроизводить текущие рабочие характеристики, но и прогнозировать их деградацию при эксплуатации.

Несмотря на достигнутый прогресс, остаются нерешённые вопросы. Большинство существующих моделей опирается либо на исторические эксплуатационные данные, либо на численные симуляции, в то время как их интеграция для формирования

комбинированных выборок исследована недостаточно. Недостаточно внимания уделено и систематической верификации моделей деградации проточной части, например, влияния роста шероховатости на аэродинамические характеристики, с использованием как *CFD*, так и телеметрических данных.

Исходя из этого, цель настоящего исследования заключается в разработке и проверке применимости прогнозной модели технического состояния к центробежному компрессору, предназначенной для использования при планировании периодичности технического обслуживания. В работе рассматривается подход, основанный на моделировании процессов деградации поверхности проточной части методами вычислительной газодинамики через рост её шероховатости. Для получения обучающей выборки в работе применяется физически обоснованная генерация синтетических сценариев деградации на базе цифрового двойника первой ступени центробежного компрессора и последующего формирования временных рядов рабочих параметров.

МЕТОДЫ, РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Современная практика технической диагностики центробежных компрессоров требует создания цифровых моделей, которые не только точно воспроизводят физику процессов в проточной части, но и учитывают изменения, вызванные эксплуатационным износом. Такие модели позволяют предсказывать снижение эффективности оборудования, вызванное эрозией и накоплением загрязнений на обтекаемых газом поверхностях, что подтверждается современными *CFD*-исследованиями по исследованию влияния шероховатости этих поверхностей [13, 14]. В частности, применение современных *CFD*-моделей также позволяет учитывать влияние шероховатости проточной части на аэродинамику, что подтверждают *Zhang et al.* [15]. Результаты этих исследований показывают, что увеличение шероховатости поверхности корпуса или лопаток может снижать КПД до нескольких процентов, что существенно для энергетической эффективности и планирования технического обслуживания.

В данном исследовании моделирование деградации поверхностей проточной части ступени центробежного компрессора производится с помощью численного моделирования в *ANSYS CFX*, позволяющего реализовать детализированные 3D-симуляции. Применение *CFD* позволяет учитывать характер течения в пограничных слоях потока, учитывая реальные геометрические параметры проточной части. Результаты работ [16] и [17] подтверждают эффективность численного подхода для анализа влияния деградации на аэродинамическую производительность компрессорной ступени.

Кроме того, современные исследования демонстрируют эффективность использования цифровых двойников и методов онлайн-мониторинга для прогнозирования деградации и планирования обслуживания оборудования. Такие цифровые модели позволяют интегрировать данные с сенсоров, статистические и физические модели, а также методы машинного обучения для оценки состояния оборудования, прогнозирования оставшегося ресурса и выявления потенциальных отказов. Такие подходы позволяют более достоверно учитывать влияние эксплуатационных факторов, таких как износ, загрязнение и шероховатость, на работу компрессора.

Объектом исследования выбрана первая ступень центробежного компрессора, наиболее подверженная воздействию механических примесей, конденсата и химически активной среды. Геометрическая модель ступени построена в среде *ANSYS CFX* параметрически, что позволяет варьировать все основные геометрические параметры элементов проточной части, такие как рабочее колесо и обратно-направляющий аппарат. Этот подход согласуется с рекомендациями по параметрическому моделированию для оценки влияния шероховатости на КПД и давление, описанными в исследованиях *Alqallaf et al.* [13].

Для проведения верификации результатов моделирования был произведен проектный газодинамический расчет прототипа реального производственного объекта — центробежного компрессора на дожимной

компрессорной станции газового промысла №3С. Были использованы фактические эксплуатационные значения давления на входе и выходе компрессора, расход газа, скорость вращения ротора. На основе этих данных и с применением проектной методики НЗЛ был выполнен газодинамический проектный расчёт цифрового прототипа компрессора для дальнейшего численного эксперимента с учетом шероховатости поверхности проточной части [18]. Следует отметить, что использование такого подхода не обеспечивает полного повторения формы проточной части реального компрессора, но для задач оценки применимости методики прогнозирования деградации поверхностей через рост значения условной песочной шероховатости является приемлемым допущением.

В данной исследовательской работе использование данных реального компрессора для построения его цифрового прототипа позволяет продемонстрировать применимость прогностических методик деградации поверхности проточной части [19].

В таблицах 1, 2, 3 представлены параметры исследованной первой ступени цифрового прототипа центробежного компрессора, включая геометрические параметры, полученные по результатам газодинамического проектного расчета. Элементами исследуемой ступени являются: рабочее колесо (РК), безлопаточный диффузор (БЛД), обратно-направляющий аппарат.

Контрольными сечениями в ступени являются:

- сечение 0–0 — вход в ступень компрессора;
- сечение 1–1 — вход на лопатки рабочего колеса;
- сечение 2–2 — выход из рабочего колеса;
- сечение 3–3 — вход в безлопаточный диффузор;
- сечение 4–4 — выход из безлопаточного диффузора;
- сечение 5–5 — вход в обратно-направляющий аппарат;
- сечение 6–6 — выход из обратно-направляющий аппарата;
- сечение 0'–0' — выход из ступени компрессора.

Таблица 1²

Геометрические и рабочие параметры рабочего колеса первой ступени центробежного компрессора¹

Параметр Parameter	Обозначение Symbol	Размерность Units	Значение Value
число ступеней number of steps	X	-	3
Скорость вращения ротора	n	об/мин	5300
Диаметр рабочего колеса Impeller diameter	D_2	м	0.7
Угол выхода лопаток Blade exit angle	$\beta_{л2}$	град	48
Диаметр входа на лопатки Blade inlet diameter	D_1	м	0.35
Угол лопаток рабочего колеса на входе Angle of the impeller blades at the inlet	$\beta_{л1}$	град	45
Плотность газа по статическим параметрам на входе в ступень Gas density based on static parameters in inlet	ρ_0	кг/м ³	34.64
Статическое давление газа на входе в ступень Static gas pressure in the first section	P_0	МПа	4.51
Температура газа на входе в ступень Gas temperature at stage inlet	T_0	К	285.63
Абсолютная скорость потока газа при входе на лопатки Absolute gas flow velocity at the inlet to the blades	C_1	м/с	93.98

Таблица 2⁴

Геометрические и рабочие параметры безлопаточного диффузора (БЛД) первой ступени центробежного компрессора³

Параметр Parameter	Обозначение Symbol	Размерность Units	Значение Value
Ширина канала БЛД в сечении 3 VLD channel width	b_3	м	0.06
Ширина канала БЛД в сечении 4 VLD channel width	b_4	м	0.06
Диаметр входа в БЛД VLD inlet diameter	D_3	м	0.77
Диаметр выхода из БЛД VLD outlet diameter	D_4	м	1.19
Статическое давление газа в сечении 4-4 Static gas pressure in section 4-4	P_4	МПа	5.46
Полное давление в сечении 4-4 Total pressure in cross section 4-4	P_4^*	МПа	5.51

Таблица 3⁶

Геометрические и рабочие параметры поворотного колена и обратно-направляющего аппарата первой ступени центробежного компрессора⁵

Радиус наружной поверхности поворотного колена Outer surface radius of the return bend	R_s	м	0.1006
Радиус внутренней поверхности поворотного колена Radius of the inner surface of the return bend	R_h	м	0.0503
Угол установки лопаток ОНА в сечении 5-5 Blade setting angle of the return channel at section 5-5	$\alpha_{л5}$	град	19.85

Продолжение таблицы 3

Угол установки лопаток ОНА в сечении 6-6 Blade setting angle of the return channel at section 6-6	$\alpha_{л6}$	град	90
Отношение скоростей в сечениях 0'-0' и 4-4 Velocity ratio in sections 0'-0' and 4-4	$K_{0',-4}$	-	1.3388
Абсолютная скорость в сечении 5-5 Absolute velocity in section 5-5	C_5	м/с	78.76
Статическая температура газа в сечении 5-5 Gas temperature in section 5-5	T_5	К	300.26
Плотность газа в сечении 5-5 Gas density in section 5-5	ρ_5	кг/м ³	39.41
Статическое давление газа в сечении 5-5 Static gas pressure in section 5-5	P_5	МПа	5.40
Абсолютная скорость в сечении 0'-0' Absolute velocity in section 0'-0'	$C_{0'}$	м/с	105.62
Температура газа в сечении 0'-0' Gas temperature in section 0'-0'	$T_{0'}$	К	299.26
Давление газа в сечении 0'-0' Gas pressure in section 0'-0'	$P_{0'}$	МПа	5.34
Площадь в сечениях 5-5 Area in sections 5-5	F_5	м ²	0.0595
Площадь в сечениях 0'-0' Area in sections 0'-0'	$F_{0'}$	м ²	0.04
Коэффициенты загромождения потока лопатками ОНА на входе Flow obstruction coefficients of RC blades at the inlet	τ_5	м ²	0.9342
Коэффициенты загромождения потока лопатками ОНА на выходе Flow obstruction coefficients of RC blades at the outlet	τ_6	м ²	0.9040

В качестве примера на рисунке представлена расчётная сетка рабочего колеса. Общее число элементов сетки для первой ступени центробежного компрессора составляет 1 056 875. Аналогичным образом была построена сетка для безлопаточного диффузора, однако в связи с простотой его геометрической формы она не приводится. Построенные сетки для рабочего колеса (РК) и обратно-направляющего аппарата (ОНА) с поворотным коленом показаны на рисунках 1 и 2 соответственно. Для повышения точности расчётов вблизи твёрдых стенок выполнено локальное сгущение сетки. Применены интерфейсы *frozen rotor* между элементами проточной части. Рабочим телом выбран метан с идеальными свойствами, то есть без учета проявления его реальных свойств через коэффициент сжимаемости. При данных расчетных давлениях у метана проявляются свойства сжимаемости, но в представленном исследовании оценки прогностических моделей падения КПД в связи с ростом шероховатости учет реальности газа не является влияющим параметром и поэтому для снижения ресурсоемкости моделирования потока реальность газа не учитывалась.




Рис. 1. Лопатка рабочего колеса с наложенной расчетной сеткой.⁷
Fig. 1. Impeller blade with overlaid computational mesh.

Проведено численное моделирование потока природного газа при гидравлически гладких поверхностях. В расчетной области первой ступени центробежного компрессора в программной среде ANSYS CFX при гидравлически гладких стенках. В таблице 4 приведено сравнение полученных результатов численного эксперимента прототипа ступени с расчетными данными, определёнными по методике НЗЛ. Сравнение демонстрирует отклонения параметров в пределах до 1.13%.

На рисунках 1,2 показаны лопатка рабочего колеса, лопатка обратно-направляющего аппарата. Формируются пространственные распределения скоростей, давлений, температур и других производных параметров потока, визуализация которых представлена на рисунках 3, 4, 5, а также линий тока и значений скорости потока в безлопаточном диффузоре в радиальной развертке на рисунке 6.




Рис. 2. Лопатка обратно-направляющего аппарата и поворотное колено с наложенной расчетной сеткой.⁸

Fig. 2. Guide vane blade and bend with overlaid computational mesh.




Рис. 3. Линии тока и значения скорости потока для первой ступени компрессора.⁹

Fig. 3. Streamlines and flow velocity distribution for the first stage of the compressor.

Ключевым элементом методики прогнозирования ухудшения коэффициента технического состояния является введение прогрессирующих признаков деградации, отражающих износ компрессора. В исследовании используется CFD-моделирование с заданием эквивалентной песочной шероховатости, одинаковой для всех поверхностей, что позволяет учитывать совокупное влияние коррозии, эрозии,

отложений и микротрещин без их дифференциации.




Рис. 4. Распределение поля давлений в первой ступени.¹⁰

Fig. 4. Pressure field distribution in the first stage.




Рис. 5. Распределение поля температур в первой ступени.¹¹

Fig. 6. Temperature field distribution in the first stage.




Рис.6. Линии тока и значения относительной скорости потока в рабочем колесе и абсолютной скорости потока в безлопаточном диффузоре на средней высоте лопатки.¹²

Fig. 6. Streamlines and values of relative flow velocity in the impeller and absolute flow velocity in the vaneless diffuser at the mid-blade height.

Сравнение результатов¹³

Параметр Parameter	Размерность Units	Отклонение Deviation	Результаты расчёта по методике НЗЛ Calculation results using the NZL method	Результаты численного моделирования Numerical simulation results
Массовый расход Mass flow rate	$\frac{\text{кг}}{\text{с}}$	1.13%	184.8	186.9
Давление в сечении 0-0 Pressure in section 0-0	МПа	0.021%	4.68	4.679
Температура газа в сечении 0-0 Gas temperature in section 0-0	К	0.003%	288.15	288.14
Температура газа в сечении 0'-0' Gas temperature in section 0'-0'	К	0.13%	300.16	299.74
Давление в сечении 0'-0' Pressure in section 0'-0'	МПа	0.18%	5.39	5.38

Серия *CFD*-расчётов при различных значениях шероховатости формирует зависимость падения коэффициента полезного действия (КПД) от времени эксплуатации, отражая реальную динамику деградации. Полученные данные позволяют установить количественные связи между параметром шероховатости и эксплуатационными характеристиками — давлением, температурой и КПД, формируя основу для построения временных рядов деградации.

Синтетическая выборка, сформированная по результатам численных экспериментов, используется для обучения моделей машинного прогнозирования технического состояния при дефиците реальных данных.

Исследованы следующие методы машинного обучения и статистического моделирования для прогнозирования падения КПД компрессорной ступени:

- 1) Экспоненциальная регрессия с линейной частью — моделирует снижение параметров по мере течения времени эксплуатации, учитывая изменение значений давлений и

температур на выходе из компрессора при постоянной скорости вращения ротора и росте шероховатости поверхности по времени в линейной форме. Такая комбинация позволяет явно учесть временной фактор и отдельные эксплуатационные параметры.

- 2) Полиномиальная регрессия с регуляризацией *Ridge* — расширяет исходные признаки комбинациями и квадратами (полиномиальные признаки), что позволяет учитывать взаимодействие факторов. L2-регуляризация предотвращает переобучение на ограниченной выборке данных.
- 3) Случайный лес (*Random Forest Regressor*) — ансамблевая нелинейная модель деревьев решений, способная выявлять сложные зависимости между шероховатостью рабочих поверхностей, параметрами потока (давлением и температурой) и КПД компрессора без необходимости явного задания формы зависимости.

- 4) *Gaussian Process Regression (GPR)* — вероятностная нелинейная модель, основанная на теории гауссовских процессов, которая описывает зависимость между параметрами в виде случайной функции с заданным ковариационным ядром. Модель не требует явного задания формы зависимости и оценивает не только прогнозируемое значение, но и степень неопределённости предсказания. Благодаря этому *GPR* обеспечивает высокую интерпретируемость результатов и особенно эффективна при работе с небольшими объёмами экспериментальных данных.
- 5) *XGBRegressor* — ансамблевая нелинейная модель градиентного бустинга на деревьях решений, способная точно описывать сложные взаимосвязи между эксплуатационными параметрами. Модель последовательно строит множество деревьев, где каждое последующее дерево корректирует ошибки предыдущих, за счёт чего достигается высокая точность прогнозирования. Благодаря встроенной регуляризации и гибким настройкам параметров, *XGBRegressor* эффективно предотвращает переобучение и обеспечивает устойчивость при работе с шумными и разнородными данными.

Для оценки точности моделей использовались следующие метрики:

RMSE (Root Mean Squared Error) — среднеквадратичная ошибка, чувствительная к крупным отклонениям и выбросам.

MAE (Mean Absolute Error) — средняя абсолютная ошибка, менее чувствительна к выбросам и отражает среднее отклонение прогнозов.

R^2 (коэффициент детерминации) — доля объяснённой дисперсии, позволяет оценить, насколько хорошо модель воспроизводит динамику наблюдаемых данных.

MAPE (Mean Absolute Percentage Error) — процентная оценка ошибок, удобна для интерпретации в относительных величинах.

Существуют количественные зависимости между техническим состоянием компрессора, выраженным через уровень шероховатости, и его энергетическими характеристиками — адиабатным КПД, массовым расходом,

давлением и температурой в конце процесса сжатия. На основе этих зависимостей строится математическая прогностическая модель, которая позволяет предсказывать момент необходимости технического обслуживания по достижению минимально допустимого значения КПД компрессора.

В качестве варьируемого фактора рассматривается только шероховатость стенок проточной части, изменяющаяся от исходного состояния до критических значений, имитирующих загрязнение и эрозию. На каждом этапе фиксируются ключевые выходные параметры: давление, температура при неизменных для всех численных экспериментов скорости вращения ротора, массовом расходе и давлении и температуре на входе. Для проведенных 61 численных экспериментах при различной шероховатости поверхности проточной части получены данные по температуре и давлению на выходе из ступени, формирующих обучающую выборку для последующего анализа.

Обучающий набор синтетических данных, полученных по результатам CFD-моделирования, показан в таблице 3.

Значение адиабатического КПД было получено по формуле:

$$\kappa$$

где κ — показатель адиабаты, R — газовая постоянная, T_0 — начальная температура, T_1 — конечная температура, P_0 — начальное давление, P_1 — конечное давление, C_p — удельная изобарная теплоемкость метана,

Полученные сравнительно невысокие значения адиабатического КПД ступеней объясняются дополнительными аэродинамическими потерями, возникающими вследствие загрязнения и эрозионного износа проточной части компрессора. Эти эффекты учтены в моделировании через параметр шероховатости поверхностей лопаток и каналов, который имитирует деградацию состояния проточной части при длительной эксплуатации. Увеличение шероховатости приводит к росту гидравлического сопротивления и потерь на трение, что вызывает снижение КПД ступени при неизменных входных условиях.

Таблица 5¹⁶.

Набор синтетических данных¹⁵

№	дни day	месяцы months	Ra (мкм) Ra (μm)	P ₀ (Па) P ₀ (Pa)	P ₀ (Па) P ₀ (Pa)	T ₀ (K) T ₀ (K)	T ₀ (K) T ₀ (K)	КПД адиабатный isentropic efficiency
1	7	0.23	10.81	4679540	5359671	288.15	299.91	79.73
2	14	0.46	10.87	4679540	5359421	288.15	299.90	79.72
3	21	0.70	10.92	4679540	5359071	288.15	299.90	79.69
4	28	0.90	10.98	4679540	5358771	288.15	299.89	79.67
...								
59	371	12.80	87.56	4679540	5335873	288.15	299.75	78.13
60	378	12.81	89.20	4679540	5335614	288.15	299.75	78.10
61	385	12.83	90.83	4679540	5335355	288.15	299.75	78.07

В работе применялись пять моделей для прогнозирования КПД компрессоров с учётом ограниченного объёма данных для обучения. Также применялись библиотеки *Python* (*NumPy*, *Pandas*, *TensorFlow*, *Keras*, *Scikit-learn*) для обработки данных и обучения моделей.

Все данные *CFD*-расчетов были разделены на обучающую выборку в количестве 80% от общего числа расчетов, по которой производилось обучение моделей прогнозирования, и тестовую выборку в количестве 20% расчетов, по которой проверялось качество обучения моделей. При этом выбор обучающих и тестовых результатов *CFD*-расчетов произведен в случайном порядке во всем временном диапазоне. Фактическое падение КПД для исследуемого цифрового прототипа показано на рисунке 7.

Первая прогностическая модель представляет собой комбинированную экспоненциально-линейную регрессию для прогнозирования разности температуры (ΔT) и давления (ΔP) между входом и выходом компрессора. Использование разностей (ΔT , ΔP) позволяет непосредственно отслеживать абсолютную деградацию рабочих характеристик компрессора, поскольку в таких инженерных системах деградация обычно проявляется через линейное (или квазилинейное) снижение перепада температуры и давления со временем. Экспоненциальный фактор деградации в модели как раз отражает этот процесс, фиксируя постоянные или почти постоянные

^{15,16} Appendix 1 шаге эксплуатации. Такой подход проще интерпретируется,

обеспечивает стабильность анализа и прогноза трендов деградации, а также более нагляден для мониторинга технического состояния агрегата. В данной модели учитывается деградация рабочих характеристик во времени через экспоненциальный фактор с коэффициентом затухания $k=0.2$, в то время как остальные признаки — шероховатость поверхности, входные температура и давление — включаются в модель линейно. Такой подход позволяет явно моделировать снижение эффективности компрессорного оборудования с течением времени, сохраняя при этом физическую интерпретируемость влияния технологических параметров.

В выводе модели представлены следующие показатели качества: для изменения температуры (ΔT) коэффициент детерминации на тестовой выборке составляет $R^2 = 0.9968$, среднее значение R^2 по кросс-валидации равно 0.9941 со стандартным отклонением 0.0031; для изменения давления (ΔP) получены еще более высокие показатели — R^2 на тесте равно 0.9994, среднее R^2 по кросс-валидации равно 0.9989 с минимальным стандартным отклонением 0.0006. Прогнозируемые значения изменений на будущие периоды демонстрируют закономерное снижение разницы давлений ΔP с 627765 Па (15 месяцев) до 615183 Па (18 месяцев), что отражает постепенную деградацию рабочих характеристик компрессора.

Проверка на переобучение выполняется через анализ разрыва между метриками обучающей и тестовой выборки (*gap*), а также через оценку стабильности кросс-валидации. *Gap* представляет собой разность между

значениями метрики на обучающей и тестовой выборках, измеряемую в единицах самой метрики; значения менее 0.01 (1%) считаются отличными показателями отсутствия переобучения, где малые положительные значения (<0.01) или отрицательные указывают на отсутствие переобучения. Для обеих целевых переменных *gap* составляет менее 0.002, что указывает на отсутствие значимого переобучения. Модель классифицирована как стабильная, что подтверждается низкими значениями стандартного отклонения кросс-валидации и отрицательными значениями *gap*, свидетельствующими о хорошей обобщающей способности.

Основными преимуществами разработанной модели являются физически обоснованное моделирование временной деградации оборудования, высокая точность прогнозирования ($R^2 > 0.99$), устойчивость к переобучению и возможность интерпретации вклада каждого технологического параметра. Ограничения модели связаны с предположением о линейном характере влияния большинства признаков и фиксированной экспоненциальной форме временной зависимости, что может снижать точность при наличии более сложных нелинейных взаимодействий между параметрами процесса.

Вторая модель представляет собой регрессию *Ridge* на полиномиальных признаках с автоматическим отбором наиболее значимых комбинаций факторов. Модель использует масштабирование признаков с помощью *StandardScaler*, расширение исходных признаков до полиномиальных комбинаций второго порядка и селекцию наилучших признаков с помощью *SelectKBest*. В результате *nested* кросс-валидации для обеих целевых переменных выбрано оптимальное количество признаков, равное 27 при степени полинома 2 и коэффициенте регуляризации $\alpha = 0.1$. L2-регуляризация ограничивает величину коэффициентов и снижает риск переобучения, а автоматический отбор признаков позволяет включать только значимые взаимодействия между технологическими параметрами.

Анализ метрик демонстрирует высокое качество модели: для температуры среднее R^2 по *outer* кросс-валидации составляет 0.9775 ± 0.0216 с $RMSE = 0.005466$, *hold-out* $R^2 = 0.9975$ и $RMSE = 0.002646$; для давления

среднее R^2 по кросс-валидации равно 0.9943 ± 0.0030 с $RMSE = 645.96$, *hold-out* $R^2 = 0.9998$ и $RMSE = 169.33$. Полная кросс-валидация на всех данных показала $R^2 = 0.9950$ для температуры и $R^2 = 0.9995$ для давления. Проверка на переобучение через анализ *gap* между полной и внешней кросс-валидацией ($+0.0174$ для температуры и $+0.0052$ для давления) указывает на стабильность модели без значимого переобучения.

К преимуществам *Ridge* регрессии на полиномиальных признаках относится способность автоматически выявлять и учитывать взаимодействия между технологическими параметрами, высокая интерпретируемость коэффициентов модели и эффективное предотвращение переобучения. Основными ограничениями являются предположение о полиномиальном характере зависимостей, необходимость балансировки между сложностью модели и обобщающей способностью, а также потенциальная чувствительность к выбросам при работе с малыми выборками данных.

Третья модель построена на методе *Random Forest Regressor*, который представляет собой ансамблевый алгоритм, основанный на множестве деревьев решений. Каждое дерево обучается на случайной подвыборке данных (*bootstrap sampling*) и случайном наборе признаков, а итоговое предсказание формируется усреднением прогнозов всех деревьев. В данном исследовании для *Random Forest* использовались оптимальные гиперпараметры: 400 деревьев, максимальная глубина 10, минимальное количество образцов в листе равное 1 и использование всех признаков на каждом разбиении.

Анализ метрик демонстрирует различное качество прогнозирования для двух целевых переменных. Для температуры на тестовой выборке R^2 составил 0.8741 при $RMSE = 0.018767$, в то время как на обучающей выборке R^2 достиг 0.9923 с $RMSE = 0.003983$. Среднее значение R^2 по 5-фолдовой кросс-валидации составило 0.9581 ± 0.0456 , при этом лучший внутренний CV R^2 равен 0.9544. Для давления результаты оказались более стабильными: тестовый $R^2 = 0.9652$ ($RMSE = 2426.56$), обучающий $R^2 = 0.9968$ ($RMSE = 522.04$), среднее R^2 по кросс-валидации равен 0.9908 ± 0.0103 с лучшим внутренним CV $R^2 = 0.9816$.

Проверка на переобучение выявила различия между целевыми переменными. Для температуры разрыв между обучающей и тестовой выборками составил +0.1183, что указывает на потенциальное переобучение и снижение обобщающей способности. Для давления разрыв равен +0.0316, что соответствует допустимому уровню и свидетельствует о стабильности модели.

Анализ важности признаков показал доминирующее влияние времени эксплуатации (43.5 % для температуры, 43.0 % для давления) и шероховатости поверхности (≈ 42.6 % для обеих переменных), что подтверждает ключевую роль деградационных процессов в изменении характеристик компрессора.

Основные преимущества Random Forest — способность выявлять сложные нелинейные зависимости без инженерии признаков, устойчивость к шуму и выбросам, а также автоматическое определение значимых взаимодействий между параметрами. К недостаткам относятся низкая интерпретируемость, риск переобучения при прогнозировании температуры и чувствительность к малым объёмам данных (в данном случае 61 наблюдение).

Четвертая модель представляет собой многоуровневую систему *Gaussian Process Regression (GPR)* с автоматическим глобальным поиском конфигураций и адаптивной инженерией признаков. В отличие от стандартных реализаций *GPR*, данная система включает автоматическое тестирование 32 конфигураций, сочетающих методы отбора признаков по взаимной информации, управление размерностью (5, 7, 9 и все признаки), использование производных признаков (*diff*-операторы) и логарифмическое преобразование давления для стабилизации масштаба. Каждая конфигурация оценивается с применением временной кросс-валидации (*TimeSeriesSplit*) и множественных ковариационных ядер — *Matern* ($\nu = 1.5, 2.5$), *RBF*, *RationalQuadratic*, а также их композиций (например, *RBF* $\times$ *Matern*). Модель автоматически формирует физически осмысленные признаки, включая отношения давлений, приросты температуры, нормированную шероховатость, лаговые переменные и временные преобразования.

Преимущества модели *GPR* включают автоматическую оценку неопределённости

(байесовская природа), физически интерпретируемые ядра *Matern*, отражающие гладкость деградации, устойчивость к переобучению и способность выявлять сложные временные зависимости без явной авторегрессии. К ограничениям относятся высокая вычислительная сложность (≈ 640 обучений при глобальном поиске), чувствительность к утечкам данных и ограниченная масштабируемость на выборках свыше 1000 наблюдений из-за кубической сложности операций с ковариационными матрицами.

Пятая модель — оптимизированная система *XGBRegressor* с автоматическим подбором конфигурации и расширенной инженерией признаков. Модель включает предобработку данных с тестированием трёх методов скейлинга, многоуровневый отбор признаков (корреляция, взаимная информация, *RFE*) и автоматическое создание новых физически обоснованных признаков. Тестируются пять конфигураций *XGBoost* с двухэтапной оптимизацией гиперпараметров через *GridSearchCV*.

Результаты: для температуры оптимизированная модель достигла *Test* $R^2 = 0.9510$ ($RMSE = 0.0133$, $MAE = 0.0061$) при *CV* $R^2 = 0.9137 \pm 0.1273$; для давления базовая *xgb_medium* показала *Test* $R^2 = 0.9779$, *CV* $R^2 = 0.9906 \pm 0.0082$, и дальнейшая оптимизация не улучшила показатели. Комплексная метрика качества составила 0.8514 для температуры и 0.9672 для давления.

Преимущества модели — автоматический выбор конфигурации, физически мотивированная инженерия признаков, устойчивость к переобучению и выявление сложных нелинейных взаимодействий. Ограничения — высокая вычислительная сложность, нестабильность на малых выборках и снижение интерпретируемости по сравнению с линейными методами.

Наилучшие результаты в прогнозировании деградации параметров компрессора показала комбинированная экспоненциально-линейная регрессия, использующая дифференциальный подход и физически обоснованную экспоненциальную зависимость для моделирования износа оборудования. Модель продемонстрировала высокую точность при минимальном разрыве между обучением и тестом (*Gap* < 0.002), обеспечив оптимальный баланс простоты и устойчивости за счёт пяти параметров и композитной метрики качества.

Второе место по точности заняла *Ridge*-регрессия на полиномиальных признаках, которая благодаря учёту нелинейных взаимодействий обеспечила сопоставимую точность, однако показала меньшую стабильность (*Gap* до 0.0174). Таким образом, лидерство экспоненциально-линейной модели объясняется её простотой, интерпретируемостью и соответствием реальной динамике деградационных процессов.

Простая линейная модель с взаимодействиями (*Ridge*) показала наилучшие результаты благодаря сочетанию статистических, физических и структурных факторов данных. При небольшом размере выборки ($N=61$) такие модели обладают оптимальным соотношением между числом параметров и количеством наблюдений (~12 наблюдений на параметр), что предотвращает переобучение. *Ridge*-регуляризация стабилизирует коэффициенты при наличии коррелированных признаков (например, времени и шероховатости), обеспечивая устойчивость и сглаживание оценок. Кроме

того, взаимодействия между признаками имеют физический смысл: влияние шероховатости на параметры компрессора (давление, температуру и КПД) не является строго линейным и проявляется через мультипликативные эффекты. Линейная модель с такими взаимодействиями способна точно захватить эти закономерности без чрезмерной сложности. В отличие от экспоненциальных моделей, которые при малом числе данных усиливают шум и теряют физическую интерпретируемость, *Ridge*-модель обеспечивает лучший баланс между смещением и дисперсией. Высокие показатели подтверждают, что она демонстрирует отличную генерализацию, стабильность и минимальный разрыв между обучением и тестом. Таким образом, точность для данной задачи линейной модели объясняется не случайностью, а соответствием принципу бритвы Оккама и физическим свойствам деградации компрессора, которая на рассматриваемом временном интервале протекает почти линейно




Рис. 7. График падения адиабатного КПД первой ступени центробежного компрессора по результатам численного моделирования при росте шероховатости поверхностей проточной части с увеличением времени эксплуатации и результаты обучения прогностической модели методами *Ridge Regression*.¹⁷

Fig. 7. Plot of the adiabatic efficiency drop of the first stage of a centrifugal compressor according to numerical simulation results with increasing flow-surface roughness over operational time, and the results of training the predictive model using Ridge Regression methods.

Представленная работа отличается подходом к прогнозированию технического состояния центробежных компрессоров промышленного назначения, основанным на интеграции *CFD*-моделирования, методов машинного обучения и физически

¹⁷ Appendix 1 моделирования деградации поверхностей проточной части.

Деградация описывается через рост эквивалентной песочной шероховатости, а результаты *CFD*-симуляций используются для генерации физически достоверных синтетических данных при обучении моделей. Такой подход компенсирует дефицит эксплуатационных данных, сохраняя физическую интерпретируемость процессов.

Впервые проведено системное сравнение пяти методов прогнозирования — экспоненциально-линейной регрессии, полиномиальной регрессии с регуляризацией *Ridge*, *Random Forest*, *Gaussian Process Regression (GPR)* и *XGBRegressor*, что позволило определить оптимальный баланс между точностью и устойчивостью при ограниченном объёме данных.

В отличие от работ [20] и [21], где исследовалось исключительно аэродинамическое влияние шероховатости без прогнозирования деградации, данная работа объединяет CFD-моделирование, генерацию синтетических данных и машинное прогнозирование снижения КПД в единую методологию, применимую для предиктивного обслуживания промышленных центробежных компрессоров.

ЗАКЛЮЧЕНИЕ

В рамках настоящего исследования была разработана и проверена применимость прогнозной модели технического состояния поверхности проточной части первой ступени центробежного компрессора, предназначенной для планирования периодичности технического обслуживания. Основной акцент работы был сделан на интеграции численного моделирования газодинамических процессов и методов машинного прогнозирования для оценки деградации КПД компрессора под воздействием эксплуатационного износа и изменений шероховатости проточной части.

Проведённые численные исследования в *ANSYS CFX* показали высокую физическую достоверность моделирования проточной части. Полученные распределения скоростей, давления и температуры газа, а также другие производные параметры потока были верифицированы. Верификация показала, что отклонения ключевых параметров от проектных данных не превышают 1.5%, что позволяет использовать модель для формирования синтетических обучающих выборок для прогнозирования деградации.

Особое внимание было уделено количественной оценке влияния роста шероховатости на энергетические характеристики компрессора. Моделирование различных сценариев деградации позволило выявить комплексные зависимости между шероховатостью стенок и такими параметрами, как давление, температура и

адиабатный КПД. Эти зависимости были использованы для формирования временных рядов, отражающих динамику снижения эффективности оборудования в ходе эксплуатации, что позволило создать обучающие наборы данных для дальнейшего машинного обучения.

Для анализа деградации адиабатического КПД были применены различные подходы машинного обучения, включающие как линейные, так и нелинейные методы. На начальном этапе рассматривались экспоненциальные и полиномиальные регрессии, а также ансамблевые модели на основе деревьев решений. Экспоненциальная регрессия с линейной компонентой обеспечила физически интерпретируемое описание временного снижения КПД, однако показала высокую чувствительность к шуму и склонность к переобучению на ограниченном наборе данных. Полиномиальная регрессия с регуляризацией *Ridge* продемонстрировала высокую точность и способность учитывать взаимодействия признаков, однако её преимущества по сравнению с линейной моделью оказались несущественными при анализе ограниченной выборки.

Наиболее устойчивые и физически обоснованные результаты были получены при использовании линейной модели с взаимодействиями и регуляризацией *Ridge*. Эта модель показала наивысшие значения коэффициента детерминации (R^2 до 0.9995) при минимальном разрыве между обучающей и тестовой выборками, что свидетельствует о её способности корректно обобщать закономерности деградации без переобучения.

Модели *Random Forest* и *XGBoost* показали формально высокие показатели точности, однако их интерпретируемость и устойчивость оказались ограниченными. *Random Forest* выявлял сложные нелинейные зависимости, но имел признаки переобучения при малом объёме данных (61 наблюдение), а модель *XGBoost* продемонстрировала искусственно завышенные метрики вследствие частичной утечки данных через производные признаки. Эти особенности делают их менее надёжными для применения в прогнозных задачах с ограниченными экспериментальными выборками.

Проведённый анализ метрик качества показал, что линейная модель с *Ridge*-регуляризацией является оптимальной для

прогнозирования деградации КПД компрессора по причинам роста шероховатости поверхности проточной части. Она сочетает в себе физическую интерпретируемость, устойчивость и высокую точность, что делает её предпочтительным инструментом для практических задач технической диагностики и предиктивного обслуживания.

БИБЛИОГРАФИЯ (REFERENCES)

- [1] Pal N., Manzananas Lopez D., and Johnson T.T. 'Robustness Verification of Deep Neural Networks using Star-Based Reachability Analysis with Variable-Length Time Series Input', arXiv preprint arXiv:2307.13907, Jul. 2023.
- [2] Dwivedi D., Moses B.K.V.S., Yemula P.K., Chakraborty P., and Pal M. 'Identification of Surface Defects on Solar PV Panels and Wind Turbine Blades Using Attention-Based Deep Learning Model', arXiv preprint arXiv:2211.15374, Jan. 2024.
- [3] Barbosa A.M., Ngo T.V.N., Jafarigol E., and Trafalis T.B. 'Using Federated Machine Learning in Predictive Maintenance of Jet Engines', arXiv preprint arXiv:2502.05321, Feb. 2025, doi: 10.48550/arXiv.2502.05321.
- [4] Shah S.S., Tan D., and Kumar S.C. 'RUL Forecasting for Wind Turbine Predictive Maintenance Based on Deep Learning', *Heliyon*, vol. 10, p. e39268, Oct. 2024, doi: 10.1016/j.heliyon.2024.e39268.
- [5] Selvaraj S., Venkataraman R., and Ganesan M. 'Predicting Remaining Useful Life of Turbofan Engines Using Degradation Signal Based Echo State Network', *International Journal of Turbo and Jet Engines*, 2022, doi: 10.1515/tjj-2022-0007.
- [6] Asif O., Haider S.A., Naqvi S.R., Kwak K.-S., Zaki J.F.W., and Islam S.M.R. 'A Deep Learning Model for Remaining Useful Life Prediction of Aircraft Turbofan Engine on C-MAPSS Dataset', *IEEE Access*, vol. 10, pp. 95425–95440, Sep. 2022, doi: 10.1109/ACCESS.2022.3203406.
- [7] Almuraia A., He F., and Khan M. 'AI-Driven Maintenance Optimisation for Natural Gas Liquid Pumps in the Oil and Gas Industry: A Digital Tool Approach', *Processes*, vol. 13, p. 1611, May 2025, doi: 10.3390/pr13051611.
- [8] Achouch M., Dimitrova M., Dhouib R., Ibrahim H., Adda M., Sattarpanah Karganroudi S., Ziane K., and Aminzadeh A. 'Predictive Maintenance and Fault Monitoring Enabled by Machine Learning: Experimental Analysis of a TA-48 Multistage Centrifugal Plant Compressor', *Applied Sciences*, vol. 13, p. 1790, Jan. 2023, doi: 10.3390/app13031790.
- [9] Chen L., Wei L., Wang Y., Wang J., and Li W. 'Monitoring and Predictive Maintenance of Centrifugal Pumps Based on Smart Sensors', *Sensors*, vol. 22, p. 2106, Mar. 2022, doi: 10.3390/s22062106.
- [10] Mitra P., Haghshenas M., Dal Santo N., Daly C., and Schmidt D.P. 'Improving CFD Simulations by Local Machine-Learned Corrections', *Proceedings of the ASME 2023 International Mechanical Engineering Congress and Exposition, IMECE2023*, New Orleans, LA, arXiv preprint arXiv:2305.00114, Apr. 2023.
- [11] Kebabsa T., Babouri M.K., Djebala A., and Ouelaa N. 'Advanced Diagnostic Techniques for Turbo Compressors: A Spectral Analysis Approach for Preventive Maintenance', *Advances in Mechanical Engineering*, vol. 16, no. 5, pp. 1–21, 2024, doi: 10.1177/16878132241252329.
- [12] Akolekar H.D., Waschowski F., Zhao Y., Pacciani R., and Sandberg R.D. 'Transition Modeling for Low Pressure Turbines Using Computational Fluid Dynamics Driven Machine Learning', *Energies*, vol. 14, p. 4680, Aug. 2021, doi: 10.3390/en14154680.
- [13] Alqallaf J., Back A., Sun S. "Blade Roughness Effects on Compressor and Engine Performance: A CFD and Thermodynamic Study", *MDPI Aerospace*, 2021, DOI: 10.3390/aerospace8110330.
- [14] Godse P.B., Akolekar H., and Pradeep A.M. 'Surface Roughness Effects in a Transonic Axial Flow Compressor Operating at Near-Stall Conditions', arXiv preprint arXiv:2409.07344, Sep. 2024, doi: 10.48550/arXiv.2409.07344.
- [15] Zhang M., Li L., Wang J. "Effect of Housing Surface Roughness on the Performance of Centrifugal Compressors", *Proceedings of the ASME Turbo Expo*, 2024, DOI: 10.1115/GT2024-84278.
- [16] Ghimire S., Yoon A., Mahmood S. "Detailed Simulations of a Three-Stage Supercritical CO₂ Compressor: Impact of Seal Teeth Cavity Leakage Flow", *MDPI Processes*, 2023, DOI: 10.3390/pr11051358.
- [17] Mo Y., Traverso T., and Magri L. "Decoder decomposition for the analysis of the latent space of nonlinear autoencoders with wind-tunnel experimental data," *Data-Centric Engineering*, vol. 5, 2024, e38, doi: 10.1017/dce.2024.31.
- [18] Ris V.F. *Tsentrifugal'nye kompressornye mashiny [Centrifugal compressor machines]*. Moscow–Leningrad: Mashinostroenie, 1964. 336 p. (In Russ.)
- [19] Goeing J., Bindon D., Hourmouziadis R. "Influence of Combined Compressor and Turbine Deterioration on the Overall Performance", *Journal of Turbomachinery*, 2020, DOI: 10.1115/1.4048335.
- [20] Jelly T.O., Nardini M., Rosenzweig M., Leggett J., Marusic I., and Sandberg R.D. "High-fidelity computational study of roughness effects on high pressure turbine performance and heat transfer", *International Journal of Heat and Fluid Flow*, vol.

103, p. 109134, 2023, doi: 10.1016/j.ijheatfluidflow.2023.109134.

- [21] Cheng H., Wang M., Zhou C., Zhao S., Lu X., and Zhu J., "Influence of Surface Roughness on a Highly Loaded Axial Compressor Stage Performance at Low Reynolds Number", International Journal of Aerospace Engineering, vol. 2021, Article ID 1208492, 18 pages, Oct. 2021, doi: 10.1155/2021/1208492.

APPENDIX1 (ПРИЛОЖЕНИЕ 1)

^{1,2}**Table 1.** Geometric and operating parameters of the first-stage impeller of a centrifugal compressor.

^{3,4}**Table 2.** Geometric and operating parameters of the vaneless diffuser (VLD) of the first-stage centrifugal compressor.

^{5,6}**Table 3.** Geometric and operating parameters of the return bend and return guide vane of the first-stage centrifugal compressor.

⁷**Fig. 1.** Impeller blade with overlaid computational mesh.

⁸**Fig. 2.** Guide vane blade and bend with overlaid computational mesh.

⁹**Fig. 3.** Streamlines and flow velocity distribution for the first stage of the compressor.

¹⁰**Fig. 4.** Pressure field distribution in the first stage.

¹¹**Fig. 5.** Temperature field distribution in the first stage.

¹²**Fig. 6.** Streamlines and values of relative flow velocity in the impeller and absolute flow velocity in the vaneless diffuser at the mid-blade height.

^{13,14}**Table 4.** Comparison of results.

^{15,16}**Table 5.** Synthetic dataset.

¹⁷**Fig. 7.** Plot of the adiabatic efficiency drop of the first stage of a centrifugal compressor according to numerical simulation results with increasing flow-surface roughness over operational time, and the results of training the predictive model using Ridge Regression methods.


Сведения об авторах.



Гончаров Роман Алексеевич, аспирант. Область научных интересов: компрессорная и холодильная техника.
E-mail: rimchikgncharov@gmail.com
ORCID: 0009-0006-8650-8965



Таукеев Батыржан Бакытжанович независимый исследователь. Область научных интересов: компрессорная и холодильная техника.
E-mail: Dagyr33@gmail.com
ORCID: 0009-0007-8098-049X



Карташов Сергей Владимирович, преподаватель практики. Область научных интересов: компрессорная и холодильная техника, системы транспорта и переработки газа, декарбонизация топливно-энергетического комплекса
E-mail: sergey.v.kartashov@gmail.com
ORCID: 0000-0001-5269-9536



Кожухов Юрий Владимирович, доцент, к.т.н. Область научных интересов: компрессорная и холодильная техника, системы транспорта и переработки газа, декарбонизация топливно-энергетического комплекса.
E-mail: Kozhukhov_yv@mail.ru
ORCID: 0000-0001-7679-9419