

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ СТЕПЕНИ ЭРОЗИОННОГО ИЗНОСА ЛОПАТОЧНОГО АППАРАТА КОМПРЕССОРНОЙ СТУПЕНИ

В.Л. Блинов

Г.А. Дерябин

И.С. Зубков

v.l.blinov@urfu.ru

deryabingleb.were@gmail.com

lamqtada@gmail.com

УрФУ, г. Екатеринбург, Российская Федерация

Аннотация

Задача прогнозирования степени эрозионного износа ступени осевого компрессора по параметрам его работы решена методами машинного обучения. Выполнен обзор актуального состояния эрозии, предложен подход к решению поставленной задачи. Разработан программный код на языке Python 3 для исследования применимости моделей и признаков. В качестве исходных данных использованы параметры работы ступени, полученные в результате численного эксперимента. Исследованы пять степеней эрозионного износа, заданные путем изменения геометрии проточной части в соответствии с известными законами его распределения. Предложены принципы формирования наборов параметров-признаков, объясняющих степень эрозионного износа. При определении степени эрозионного износа использованы простые модели машинного обучения для решения задачи классификации, из библиотеки Scikit-learn. При использовании степеней повышения давления, температуры и массового расхода через осевой компрессор лучшая точность результатов исследования составила 0,82 (максимум 1,00), при использовании параметров, которые действительно измеряются при эксплуатации, точность снижается до 0,76. Лучшие результаты показала модель случайного леса. Результаты исследования могут быть применены при разработке диагностических систем компрессоров

Ключевые слова

Эрозионный износ, техническое состояние, осевой компрессор, лопаточный аппарат, машинное обучение, численное моделирование, газотурбинная установка

Поступила 15.03.2023

Принята 27.03.2023

© Автор(ы), 2023

Работа поддержана грантом РНФ № 22-79-00169

Введение. Широкое использование газотурбинных установок (ГТУ) в различных отраслях народного хозяйства во всевозможных внешних условиях зачастую сопровождается эрозионным изнашиванием узлов и деталей вследствие их высокоскоростного обтекания воздухом с повышенным содержанием частиц пыли, песка, соли и пыльцы. Сильнее всего в ГТУ изнашивается лопаточный аппарат осевого компрессора (ОК) [1–3].

В некоторых условиях до 40 % случаев досрочного вывода оборудования из эксплуатации связано с повреждением лопаток из-за механических частиц в воздухе [1, 2]. Эрозионное изнашивание проявляется в изменении геометрии элементов проточной части и условий течения (появление срывов и помпажа, снижение КПД ОК) [4, 5], снижении прочности лопаток рабочего колеса (увеличение уровня вибрации, механическое разрушение лопаток) [6] и снижении топливной экономичности ГТУ, а в некоторых случаях может привести к выходу из строя целых узлов и неожиданному простою с последующим дорогостоящим ремонтом. Все это приводит к увеличению затрат на эксплуатацию и техническое обслуживание ГТУ.

Для предотвращения или уменьшения эрозии в ГТУ могут использоваться различные методы, такие как предварительная подготовка циклового воздуха [7], использование материалов и покрытий с повышенной устойчивостью к износу [8], а также регулярный контроль и очистка проточной части [9].

Дополнительным перспективным направлением обеспечения безопасной и эффективной эксплуатации является применение различных диагностических систем, позволяющих прогнозировать величину эрозионного разрушения и вероятное изменение характеристик оборудования. Все чаще в подобных системах применяют методы машинного обучения.

Машинное обучение — это одна из форм искусственного интеллекта, реализованная в виде математических алгоритмов и способная обучаться на множестве решений сходной задачи, или меняться и адаптироваться под влиянием внешних факторов. С помощью машинного обучения можно решить задачу не прямым способом, а на основании множества других успешных решений. Выделяют два основных подхода к машинному обучению: обучение с учителем (обучение проходит по размеченным учителем данным) и без учителя (алгоритму требуется определить механизм, который описывает заранее не известную структуру данных). Среди задач, решаемых с помощью машинного обучения, выделяют три: регрессию — объясняемый параметр является непрерывным числовым рядом; классификацию — объясняемый параметр является дискретной, категориальной величиной, которую нужно определить после обучения; кластеризацию — объясняемая

величина тоже дискретная, но алгоритм должен разделить данные на категории (в некоторых случаях и определить их число) без предварительного обучения. Применение методов машинного обучения в системах диагностики позволяет в короткие сроки обработать и проанализировать большой объем измеряемых параметров работы оборудования, а также повысить надежность и эффективность эксплуатации, применяя новые подходы для выявления дефектов на ранних стадиях, основанные не на физических процессах и традиционных статистических методах.

За последние годы можно условно выделить три группы исследований эрозии с помощью машинного обучения: разработка систем оценки эрозии и остаточного ресурса лопаток ГТУ; прогнозирование скорости эрозии в нефтегазовом оборудовании по экспериментальным и смоделированным данным, прогнозирование величины и местоположения эрозии на лопастях ветряных турбин.

Например, в [10] методы машинного обучения применялись для изучения скорости эрозионного износа термобарьерных покрытий деталей проточной части ГТУ. Исследователи использовали задачу регрессии, где в качестве исходных данных (245 строк) приведены оцифрованные графики из открытых литературных источников, а в качестве признаков — содержание Y_2O_3 в образце, угол воздействия, скорость и размер частиц, температура среды. Отмечено, что модель градиентного бустинга позволяет достичь наилучшей точности (R^2 до 0,66, в зависимости от способа нанесения покрытия).

Для прогнозирования скорости эрозии твердого тела в стандартных отводах, распространенных в химической и нефтегазовой отраслях [11], использована модель гауссова процесса. В качестве исходных данных задачи регрессии использовались 200 точек, полученных в результате двухмерного численного моделирования. Схожее исследование [12] прогнозирования скорости эрозии в коленах и изгибах нефтегазовой обвязки и арматуры проводилось путем решения задачи регрессии с помощью модели случайного леса. В качестве признаков в обоих исследованиях рассматривали диаметр колена, размер частиц, вязкость жидкости, материал стенки, скорость газа и жидкости. В [12] получено до 88 % верных прогнозов с учетом широкого доверительного интервала.

Создание инструмента мониторинга технического состояния авиадвигателя, который позволил бы связать эксплуатационные данные с техническим состоянием, рассмотрено в [13]. В синтетические данные внесена информация о деградации основных узлов двигателя — о степени загрязне-

ния ОК и эрозионного износа деталей турбины. Исследователи использовали задачу регрессии для прогнозирования расхода топлива и температуры на выходе из турбины и задачу классификации для выявления деградации технического состояния в ОК или турбине с помощью искусственной нейронной сети и метода опорных векторов. В задаче регрессии лучшие результаты показала нейронная сеть — RMSE (Root Mean Square Error) [14] составляет 0,009 при прогнозировании расхода и 0,01 при прогнозировании температуры. В задаче классификации лучшие результаты показал метод опорных векторов, точность составила 99,4 %.

Неисправности трехлопастной ветряной турбины классифицированы в [15]. Машинное обучение проводилось по экспериментальным данным. Исследователи пришли к выводу, что дерево логистической модели (LMT, Logistic Model Tree) имеет наибольшую точность классификации (91 %). Методами машинного обучения в [16] решались две задачи: определение местоположения эрозии (задача классификации с тремя категориями: дефекты на входной и выходной кромках, или на обеих); определение уровня эрозии (от 8 до 18 %, задача регрессии) по вибрационному сигналу и вырабатываемой мощности. Получена точность определения степени эрозионного износа $R^2 = 0,98$, точность классификации месторасположения дефекта составила 100 %.

В исследованиях по оценке или выявлению эрозионного износа для решения задач с высокой точностью могут быть применены как простые модели и ансамбли моделей, так и нейронные сети сложной архитектуры. Выбор алгоритма решения зависит от объема, качества данных и определяется индивидуально для каждой задачи. Приведенные ранее результаты исследований демонстрируют потенциал использования методов машинного обучения для прогнозирования степени эрозионного износа в газовых турбинах.

Цель настоящей работы — применение методов машинного обучения для прогнозирования состояния лопаточного аппарата ОК.

Материалы и методы решения задач, принятые допущения. В качестве объекта выбрана трансзвуковая модельная ступень NASA Stage 37 (рис. 1), результаты экспериментального исследования которой находятся в открытом доступе и являются достаточными для качественного исследования эрозионного износа [17].

Задача исследования — предсказать категорию степени эрозионного износа ступени по параметрам ее работы путем решения задачи классификации. Для решения поставленной задачи разработан программный




Рис. 1. Одноступенчатый ОК NASA Stage 37:

G — массовый расход; P_1 и P_2 — давление на входе и выходе ступени;
 T_1, T_2 и P_1^*, P_2^* — температура и полное давление на входе и выходе ступени;
 T_1^* и T_2^* — полная температура на входе и выходе ступени; M_{1rel}, M_{2rel}
и M_{1abs}, M_{2abs} — относительные и абсолютные числа Маха на входе и выходе ступени;
 c_1 и c_2 — абсолютная скорость на входе и выходе ступени; c_{1a} и c_{2a} — осевая скорость на входе и выходе ступени




Рис. 2. Алгоритм решения поставленной задачи

код на языке программирования Python. В исследовании использован алгоритм, приведенный на рис. 2.

На этапе 1 исследования осуществляли подготовку исходных данных, в качестве которых использовали результаты численных экспериментов. На этапе 2 выбирали модели машинного обучения и метрики качества, на этапе 3 формировали наборы признаков для исследования. После чего проводили машинное обучение и тестирование рассматриваемых моделей. Таким образом, исследовали различные модели и наборы признаков для них. На основании полученных результатов сформулированы рекомендации по решению поставленной задачи.

Приняты следующие допущения.

1. Исследование эрозии проводилось без учета иных факторов, влияющих на параметры работы ступени (например, загрязнений проточной части).

2. В качестве исходных данных для обучения и тестирования моделей машинного обучения использовались результаты численного эксперимента (уравнения, заложенные в математической модели, могут не полностью описывать реальные физические процессы).

3. Применение стандартных настроек моделей машинного обучения, заложенных в библиотеке [18] (подбор гиперпараметров, влияющих на работу моделей, может улучшить качество прогнозов, но не является предметом данного исследования).

Исходные данные — результаты численного моделирования в проточной части ОК с учетом и без учета эрозионного износа лопаток на различных режимах работы.

Численные расчеты выполнены в осесимметричной стационарной постановке RANS-методами. В качестве модели турбулентности использовалась $(k-\varepsilon)$ -модель; уровень сходимости расчета доводился до 10^{-6} ; сеточная модель состояла из 450 и 350 тыс. элементов для ротора и статора; интерфейс между доменами — Stage; рабочее тело — воздух, идеальный газ. На вход в расчетный домен задавались распределения полного давления и полной температуры, на выходе из домена — массовый расход. Численная модель ступени ОК верифицирована по экспериментальным данным [17] и по результатам расчетов [19]. Отклонение интегральных характеристик, полученных при численном моделировании, от экспериментальных в среднем не превышает 1 % [20].

Исходные данные получены в диапазоне эрозионного износа хорды лопаток от нуля (исходная форма) до 25,2 % (критическое значение, определяемое с помощью статистической модели для заданной геометрии лопаток ротора, после которого работа ступени не допускается [21]).

Степень эрозионного износа характеризуется максимальным изменением хорды лопатки db по высоте ступени и определяется так:

$$db = \left(1 - \frac{b_{\text{эрод}}}{b_{\text{исх}}} \right) \cdot 100 \%,$$

где $b_{\text{эрод}}$ — хорда эродированного профиля; $b_{\text{исх}}$ — хорда исходного профиля.

Всего рассмотрено пять степеней эрозионного износа: 0, 7,8, 11,2, 17,8 и 25,2 %. При этом каждой степени соответствуют различные характеры распределения эрозии по высоте лопаток [22, 23], что также оказало влияние на газодинамические характеристики ступени. Схема эрозионного износа лопаточного аппарата ступени ОК приведена на рис. 3.




Рис. 3. Схема эрозионного износа лопаточного аппарата ступени ОК

Часть исходных данных для обучения и тестирования моделей машинного обучения, полученных в результате моделирования, в графическом виде приведена на рис. 4. Здесь показаны напорные характеристики на номинальной частоте вращения ротора для степеней эрозионного износа 11,2 и 25,2 % при трех (1–3) различных характерах распределения эрозии по высоте лопаток. Аналогичные графики могут быть построены для различных конфигураций эродированных лопаток в разных координатах помимо напора и расхода и для разных частот вращения ротора. Так, в исследовании рассмотрены параметры работы на входе и выходе ступени, определенные в численном эксперименте, отмеченные на рис. 1, а также следующие рассчитанные параметры:

$$PRatio = \frac{P_2}{P_1}; \quad TRatio = \frac{T_2}{T_1};$$

$$Ad.Eff. = \frac{PRatio^{\frac{k-1}{k}} - 1}{TRatio - 1}; \quad Pol.Eff. = \frac{\ln\left(PRatio^{\frac{k-1}{k}}\right)}{\ln(TRatio)};$$

$$N = \frac{k}{k-1} RT_1 \left(PRatio^{\frac{k-1}{k}} - 1 \right) G;$$

$$\varphi = \frac{c_{2a}}{u}; \quad \psi = \frac{k}{k-1} R \frac{PRatio^{\frac{k-1}{k}} - 1}{u^2},$$

где $PRatio$ — степень повышения давления; $TRatio$ — отношение температур на входе и выходе; $Ad.Eff.$ — адиабатический КПД; $Pol.Eff.$ — политропный КПД; k — показатель адиабаты для воздуха; N — мощность;

R — универсальная газовая постоянная; φ — коэффициент расхода; c_{2a} — осевая скорость на выходе из ступени; u — окружная скорость по периферии первой ступени; ψ — коэффициент напора.

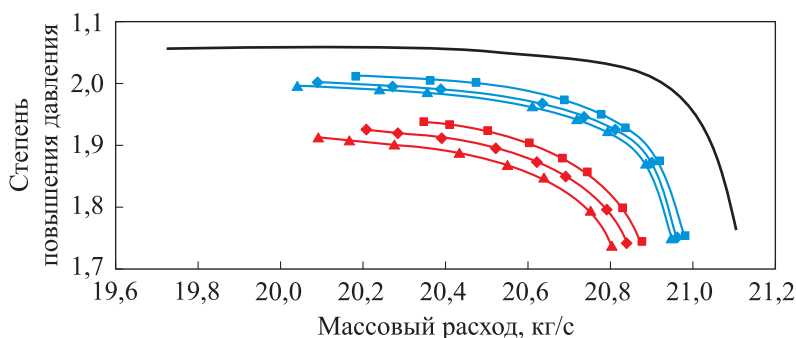


Рис. 4. Напорные характеристики для разных степеней эрозионного износа и условий работы ступени:
 $db = 0$ (—); 11,2 (—■—, —◆—, —▲— — 1, 2, 3-й характеры распределения эрозии соответственно) и 25,2 % (—■—, —◆—, —▲— — 1, 2, 3-й характеры распределения эрозии соответственно)

Всего набор исходных данных содержал 1077 вариантов расчетов (разные режимы работы, степени эрозионного износа и характеры его распределения) с более чем 30 000 значений различных параметров. Подготовка указанных данных для машинного обучения осуществлялась на этапе 1 исследования согласно алгоритму, приведенному на рис. 2.

На этапе 2 выбирались модели машинного обучения, с помощью которых будет определяться категория эрозионного износа. Для первичного исследования использовали модели для классификации, приведенные в открытой библиотеке Scikit-learn [18]: логистическую регрессию с признаками; возведенные в 1–5-ю степень; стохастический градиентный спуск; гребневую классификацию; случайный лес; дерево решений; алгоритм бустинга AdaBoost; ближайших соседей; метод опорных векторов.

В качестве целевого параметра выбрано значение степени эрозионного износа db . Значения db трансформировались в классы 0–4. Для метрики качества предложено отношение верно классифицированных образцов к числу всех образцов [24].

На этапе 3 формировались наборы признаков, которые будут использоваться для прогнозирования целевого параметра. В исследовании применяли два основных подхода к формированию групп признаков: экспертный, при котором наборы формируются вручную на основе знаний специалиста о процессах, протекающих в объекте, и алгоритмический,

при котором выбор признаков автоматизирован и происходит с помощью специальных алгоритмов.

На этапе 4 выбранные модели обучались и тестировались на наборах данных, составленных из сформированных признаков и разделенных на выборки для обучения и тестирования. Весь массив данных разделен в соотношении 0,75/0,25 для обучения и тестирования. По результатам тестирования моделей и признаков исследователи возвращались к этапам 2 и 3 для их доработки.

В результате итерационного выполнения алгоритма, описанного ранее, составлены группы признаков для исследуемых данных. Полученные наборы признаков и точность при использовании модели случайного леса приведены в таблице.

В число пяти лучших наборов признаков вошли наборы № 4 (напорные характеристики), № 6 (локальные параметры), № 7 (интегральные параметры), № 14 и 16 (наборы, полученные алгоритмически). Набор № 4 характеризует режим работы ступени и создаваемое ею изменение температуры и давления рабочего тела. Изменение технического состояния ступени непременно сказывается на них. Набор № 6 показывает локальные параметры работы ступени, которые также зависят от режима и состояния ступени. Набор № 7 включает в себя набор № 4 и энергетические характеристики ступени, такие как мощность и эффективность. Наборы № 14 и 16, а также некоторые другие, подобранные с помощью специальных алгоритмов по оценке признаков, показывают хорошие результаты, но не учитывают ограниченных возможностей измерения параметров во время эксплуатации. Наборы № 11 и 12, созданные из принципа доступности измерений, также представляют практический интерес.

Для всех наборов признаков из таблицы проведен анализ точности при использовании различных моделей машинного обучения с разной долей данных для обучения и тестирования. Точность при использовании лучших моделей (случайный лес, дерево решений, AdaBoost и ближайших соседей) с лучшим набором показана на рис. 5.

Обсуждение полученных результатов. Во всех случаях модель случайного леса показывает более высокую точность. В результате применения этой модели и набора № 4 с напорными характеристиками лучшая точность классификации степени эрозионного износа составила 0,82. Альтернативной моделью с почти такой же точностью может служить модель решающих деревьев. При обучении моделей рекомендуется использовать от 0,8 всех данных. Модели, обученные на одних данных, можно использовать для прогнозирования степени эрозионного износа по другим данным,

Сформированные наборы признаков и точность модели случайного леса по ним

Номер набора	Принцип формирования	Пояснение	Признак	Точность
<i>Экспертный вид набора</i>				
1		Все признаки по одному	<i>P*Ratio</i>	0,48
2	От данных	Все признаки вместе	$n, G, P^*Ratio, T^*Ratio, PRatio, TRatio, P_1, T_1, P_1^*, T_1^*, M_{1rel}, M_{1abs}, M_{2abs}, P_2, T_2, P_2^*, T_2^*, c_{1a}, c_{2a}, c_{11}, c_{22}, Ad.Eff., Pol.Eff., N, \Psi, \Phi$	0,80
3		Набор из лучших признаков по ϕk -корреляции	<i>PRatio, M_{2abs}, T₂, TRatio, P₂, T₁, c_{2a}, Φ, c_2, Ψ</i>	0,78
4	Интегральные характеристики	Напорные характеристики ступени	<i>P*Ratio, T*Ratio, G</i>	0,82
5		Энергетические характеристики ступени	<i>Ad.Eff., N</i>	0,61
6		Локальные параметры	$P_1, P_2, T_1, T_2, P_1^*, P_2^*, T_1^*, T_2^*, c_{11}, c_{12}, c_{1a}, c_{2a}$	0,81
7		Интегральные параметры	<i>P*Ratio, T*Ratio, Ad.Eff., N, G</i>	0,81
8	По типу параметров	Безразмерные параметры	$M_{1abs}, M_{2abs}, \Psi, \Phi$	0,78
9		Кинематические параметры	$c_{11}, c_{22}, c_{1a}, c_{2a}, M_{1abs}, M_{2abs}$	0,73
10		Термодинамические параметры	$P_1, P_2, T_1, T_2, P_1^*, P_2^*, T_1^*, T_2^*$	0,79
11	По параметрам в эксплуатации	Минимальное число измерений	T_1, P_2, n	0,76
12		Расширенное число измерений	T_1, P_1, P_2, T_2, n	0,76

Номер набора	Принцип формирования	Пояснение	Признак	Точность
<i>Алгоритмический вид набора</i>				
13		Оценка важности признаков по MDI или критерию Джинни [25]	$N, Pol.Eff., \psi, P^*Ratio, P_1^*$	0,79
14		Оценка важности признаков на основе их перестановки (MDA) [18]	$N, P_1^*, T^*Ratio, P_2^*, TRatio$	0,81
15	С помощью алгоритмов по выбору признаков	Одномерный метод выбора признаков с помощью дисперсионного анализа и F-статистики (ANOVA F-test) [26]	$P_2, M_{2,abs}, c_{2a}, T, \varphi, c_2$	0,58
16		Оценка важности признаков по весам [18]	$\psi, M_{1,rel}, T^*Ratio, TRatio, M_{1,abs}$	0,80
17	С помощью комбинаций лучших единичных признаков	1-й по точности	$P^*Ratio, T_2^*, PRatio, TRatio$	0,70
18		2-й по точности	$\psi, T_2^*, PRatio, TRatio$	0,69
19		3-й по точности	$P^*Ratio, T_2^*, PRatio$	0,69
20		4-й по точности	P^*Ratio, T_2^*	0,69
21		5-й по точности	$P^*Ratio, T_2^*, P_2^*, PRatio, TRatio$	0,69

точность при этом несколько снижается. При эксплуатации возможно применять набор признаков № 11 или 12, состоящих из измеряемых на станциях параметров. Точность при их использовании достигает 0,76, что меньше приведенной ранее, но все еще является приемлемой для получения информации о техническом состоянии ступени.




Рис. 5. Сравнение точностей моделей в зависимости от доли данных для обучения:

AdaBoost (—◆—); дерево решений (—◆—); случайный лес (—◆—); ближайшие соседи (—◆—)

При решении задачи классификации в дальнейшем также возможны разные варианты: увеличение числа категорий за счет новых уровней износа или дополнительных моделей распределения износа, сокращение числа категорий (износ отсутствует, допустимый износ, недопустимый износ), что может быть удобно при эксплуатации. При сокращении числа категорий точность прогнозирования будет возрастать.

Следует отметить, что модели, основанные на деревьях решений, не дают возможности выдавать прогноз, значение которого лежит вне диапазона, который был использован для обучения. Они также считаются сложными для интерпретации результатов. В дальнейшем переход от классификации к регрессии позволит рассматривать степень эрозионного износа как непрерывный ряд, т. е. относить текущую степень эрозионного износа не к одной из пяти категорий, а указывать точное ее значение. Это не только позволит точно оценивать текущее техническое состояние ОК, но и прогнозировать ухудшение его состояния во времени. Кроме того, модели, решающие задачу регрессии, устойчивы к разному соотношению числа эрозий разных уровней. Переход к задаче регрессии ограничивает число данных, полученных в результате численного моделирования.

Дальнейшие направления исследования связаны с учетом влияния загрязнения проточной части, других дефектов лопаточного аппарата и раз-

личных шумов в исходных данных (например, связанных с измерительным оборудованием) на параметры течения потока в ступени ОК и точность прогнозирования эрозионного износа.

Заключение. На примере изолированной ступени ОК предложен метод оценки степени эрозионного износа проточной части с помощью методов машинного обучения. Наивысшая точность составляет 0,82.

Для достижения наибольшей точности рекомендуется использовать модель случайного леса и напорные характеристики ступени P^*Ratio , T^*Ratio , G в качестве признаков. Для обучения модели следует использовать от 0,8 исходных данных.

В случае оценки технического состояния ОК по реальным данным, ограниченным числом доступных параметров, рекомендуется использовать параметры T_1 , P_2 , n . При обучении модели по ним достигнута точность 0,76.

Дальнейшее развитие работы связано с исследованием оптимального числа категорий эрозии и решением задачи регрессии для оценки ее точного уровня, а не категории. Предстоит также решить задачу по различию и оценке уровней эрозии и загрязнения ОК.

ЛИТЕРАТУРА

- [1] Burnes D., Kurz R. Performance degradation effects in modern industrial gas turbines. *Proc. Zurich Global Power and Propulsion Forum*, 2018, pp. 3–9.
- [2] Sallee G.P. Performance deterioration based on existing (historical) data. NASA report NASA-CR-135448. NASA Lewis Research Center, 1978.
- [3] Блинов В.Л., Зубков И.С., Искорцев Е.Ю. и др. Особенности численного моделирования двухступенчатого осевого компрессора с дефектными лопатками. *Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение*, 2021, т. 20, № 4, с. 7–19.
DOI: <https://doi.org/10.18287/2541-7533-2021-20-4-7-19>
- [4] Гумеров А.В., Акмалетдинов Р.Г. Моделирование эрозионного износа лопатки компрессора. *Вестник самарского государственного аэрокосмического университета им. Академика С.П. Королёва*, 2011, № 3-2, с. 233–239.
- [5] Ghenaïet A., Tan S.C., Elder R.L. Experimental investigation of axial fan erosion and performance degradation. *Proc. Inst. Mech. Eng. A*, 2004, vol. 218, no. 6, pp. 437–450.
DOI: <https://doi.org/10.1243/0957650041761900>
- [6] Двирник Я.В., Павленко Д.В. Оценка предельного состояния лопаток компрессора вертолетных ГТД по частоте собственных колебаний. *Авиационно-космическая техника и технология*, 2016, № 7, с. 79–83.

- [7] Wilcox M., Kurz R., Brun K. Technology review of modern gas turbine inlet filtration systems. *Int. J. Rotating Mach.*, 2012, vol. 2012, art. 128134.
DOI: <https://doi.org/10.1155/2012/128134>
- [8] Ефанов В.С., Прокопенко А.Н., Овчинников А.В. и др. Эрозионная стойкость лопаток компрессора вертолетных ГТД с различными типами покрытий. *Вестник двигателестроения*, 2017, № 1, с. 120–123.
- [9] Ночовная Н.А., Никитин Я.Ю. Современное состояние вопроса в области очистки проточной части компрессора ГТД от эксплуатационных загрязнений (обзор). *Труды ВИАМ*, 2017, № 3.
DOI: <https://dx.doi.org/10.18577/2307-6046-2017-0-3-5-5>
- [10] Liu Y., Ravichandran R., Chen K., et al. Application of machine learning to solid particle erosion of aps-TBC and EB-PVD TBC at elevated temperatures. *Coatings*, 2021, vol. 11, no. 7, art. 845. DOI: <https://doi.org/10.3390/coatings11070845>
- [11] Bahrainian S., Bakhshesh M., Hajidavalloo E., et al. A novel approach for solid particle erosion prediction based on Gaussian Process Regression. *Wear*, 2020, vol. 466–467, art. 203549. DOI: <https://doi.org/10.1016/j.wear.2020.203549>
- [12] Zahedi P., Parvande S., Asgharpour A., et al. Random forest regression prediction of solid particle Erosion in elbows. *Powder Technol.*, 2018, vol. 338, pp. 983–992.
DOI: <https://doi.org/10.1016/j.powtec.2018.07.055>
- [13] Giorgi M.G., Campilongo S., Ficarella A. A diagnostics tool for aero-engines health monitoring using machine learning technique. *Energy Procedia*, 2018, vol. 148, pp. 860–867. DOI: <https://doi.org/10.1016/j.egypro.2018.08.109>
- [14] Chai T., Draxler R.R. Root mean square error (RMSE) or mean absolute error (MAE)? — arguments against avoiding RMSE in the literature. *Geosci. Model Dev.*, 2014, vol. 7, no. 3, pp. 1247–1250. DOI: <https://doi.org/10.5194/gmd-7-1247-2014>
- [15] Joshuva A., Sugumaran V. A machine learning approach for condition monitoring of wind turbine blade using autoregressive moving average (ARMA) features through vibration signals: a comparative study. *Prog. Ind. Ecol.*, 2018, vol. 12, no. 1-2, pp. 14–34.
DOI: <https://doi.org/10.1504/PIE.2018.095867>
- [16] Enríquez Zárate J., Gómez López M.A., Carmona Troyo J.A. Analysis and detection of erosion in wind turbine blades. *Math. Comput. Appl.*, 2022, vol. 27, no. 1, art. 5.
DOI: <https://doi.org/10.3390/mca27010005>
- [17] Reid L., Moore R.D. Design and overall performance of four highly loaded, high-speed inlet stages for an advanced high-pressure-ratio core compressor. NASA report NASA-TP-1337. NASA Lewis Research Center, 1978.
- [18] Pedregosa F., Varoquaux G., Gramfort A., et al. Scikit-learn: machine learning in Python. *J. Mach. Learn. Res.*, 2011, vol. 12, pp. 2825–2830.
- [19] Denton J.D. Lessons from rotor 37. *J. of Therm. Sc.*, 1997, vol. 6, no. 1, pp. 1–13.
DOI: <https://doi.org/10.1007/s11630-997-0010-9>
- [20] Блинов В.Л., Дерябин Г.А., Зубков И.С. Классификация уровня эрозии проточной части изолированной ступени осевого компрессора. *Энергетические системы*, 2022, т. 7, № 1, с. 8–18.

- [21] Dvirnyk Y., Pavlenko D., Przysowa R. Determination of serviceability limits of a turboshaft engine by the criterion of blade natural frequency and stall margin. *Aerospace*, 2019, vol. 6, no. 12. DOI: <https://doi.org/10.3390/aerospace6120132>
- [22] Vogel A., Durant A., Cassiani M., et al. Simulation of volcanic ash ingestion into a large aero engine: particle–fan interactions. *J. Turbomach.*, 2019, vol. 141, no. 1, art. 011010. DOI: <https://doi.org/10.1115/1.4041464>
- [23] Потапов В.А., Санько А.А. Моделирование характеристик многоступенчатого осевого компрессора турбовального газотурбинного двигателя с учетом нелинейности эрозионного износа его лопаток. *Научный Вестник МГТУ ГА*, 2020, т. 23, № 5, с. 39–53. DOI: <https://doi.org/10.26467/2079-0619-2020-23-5-39-53>
- [24] Lever J., Krzywinski M., Altman N. Classification evaluation. *Nat. Methods*, 2016, vol. 13, no. 8, pp. 603–604. DOI: <https://doi.org/10.1038/nmeth.3945>
- [25] Han H., Guo X., Yu H. Variable selection using mean decrease accuracy and mean decrease gini based on random forest. *IEEE ICSESS*, 2016, pp. 219–224. DOI: <https://doi.org/10.1109/ICSESS.2016.7883053>
- [26] Lix L.M., Keselman J.C., Keselman H.J. Consequences of assumption violations revisited: a quantitative review of alternatives to the one-way analysis of variance *F* test. *Rev. Educ. Res.*, 1996, vol. 66, no. 4, pp. 579–619. DOI: <https://doi.org/10.3102/00346543066004579>

Блинов Виталий Леонидович — канд. техн. наук, доцент кафедры «Турбины и двигатели» УрФУ (Российская Федерация, 620002, г. Екатеринбург, ул. Мира, д. 19).

Дерябин Глеб Алексеевич — аспирант, инженер кафедры «Турбины и двигатели» УрФУ (Российская Федерация, 620002, г. Екатеринбург, ул. Мира, д. 19).

Зубков Илья Сергеевич — аспирант кафедры «Турбины и двигатели» УрФУ (Российская Федерация, 620002, г. Екатеринбург, ул. Мира, д. 19).

Просьба ссылаться на эту статью следующим образом:

Блинов В.Л., Дерябин Г.А., Зубков И.С. Применение машинного обучения для классификации степени эрозионного износа лопаточного аппарата компрессорной ступени. *Вестник МГТУ им. Н.Э. Баумана. Сер. Машиностроение*, 2023, № 4 (147), с. 88–105. DOI: <https://doi.org/10.18698/0236-3941-2023-4-88-105>

**MACHINE LEARNING INTRODUCTION TO CLASSIFY
THE EROSIIVE WEAR DEGREE OF THE COMPRESSOR
STAGE BLADES**

V.L. Blinov
G.A. Deryabin
I.S. Zubkov

v.l.blinov@urfu.ru
deryabingleb.were@gmail.com
lamqtada@gmail.com

UrFU, Ekaterinburg, Russian Federation

Abstract

The problem of predicting erosion level of an axial compressor stage based on its operating parameters was solved using the machine learning methods. Current state of erosion research using the machine learning methods was reviewed, and the approach to solving the problem was proposed. Program code was developed in the Python 3 language to study the models and features applicability. The stage operation parameters obtained as a result of the numerical experiment were used as the initial data. Five erosion degrees were studied, they were determined by changing the flow pass geometry in accordance with the known laws of the erosion wear distribution. Principles are proposed for formation of the parameter-features sets explaining the erosion degree. To determine the erosion degree, simple machine learning models were used to solve the classification problems presented in the Scikit-learn Python library. Best accuracy of the study results when using pressure and temperature ratios, as well as mass flow through the axial compressor, was 0.82 (maximum one unit). When using the parameters that were actually measured in real operation, the accuracy dropped to 0.76. The random forest model showed the best results. Study results could be introduced in design and development of the compressor diagnostic systems

Keywords

Erosive wear, technical condition, axial compressor, blade apparatus, machine learning, numerical simulation, gas turbine unit

Received 15.03.2023

Accepted 27.03.2023

© Author(s), 2023

This work was supported by the RSF (project no. 22-79-00169)

REFERENCES

- [1] Burnes D., Kurz R. Performance degradation effects in modern industrial gas turbines. *Proc. Zurich Global Power and Propulsion Forum*, 2018, pp. 3–9.
- [2] Sallee G.P. Performance deterioration based on existing (historical) data. NASA report NASA-CR-135448. NASA Lewis Research Center, 1978.
- [3] Blinov V.L., Zubkov I.S., Iskortsev E.Yu., et al. Special aspects of numerical simulation of a two-stage axial-flow compressor with defective blades. *Vestnik Samarskogo universiteta. Aerokosmicheskaya tekhnika, tekhnologii i mashinostroenie* [Vestnik of Samara University. Aerospace and Mechanical Engineering], 2021, vol. 20, no. 4, pp. 7–19 (in Russ.). DOI: <https://doi.org/10.18287/2541-7533-2021-20-4-7-19>
- [4] Gumerov A.V., Akmaletdinov R.G. Compressor blade erosion modeling. *Vestnik Samarskogo gosudarstvennogo aerokosmicheskogo universiteta im. Akademika S.P. Koroleva* [Vestnik of Samara State Aerospace University Named After Academician S.P. Korolev], 2011, no. 3-2, pp. 233–239 (in Russ.).

- [5] Ghenaiet A., Tan S.C., Elder R.L. Experimental investigation of axial fan erosion and performance degradation. *Proc. Inst. Mech. Eng. A*, 2004, vol. 218, no. 6, pp. 437–450. DOI: <https://doi.org/10.1243/0957650041761900>
- [6] Dvirnik Ya.V., Pavlenko D.V. Evaluation limit state of helicopter GTE compressor blades by frequency of natural vibrations. *Aviatsionno-kosmicheskaya tekhnika i tekhnologiya*, 2016, no. 7, pp. 79–83 (in Russ.).
- [7] Wilcox M., Kurz R., Brun K. Technology review of modern gas turbine inlet filtration systems. *Int. J. Rotating Mach.*, 2012, vol. 2012, art. 128134. DOI: <https://doi.org/10.1155/2012/128134>
- [8] Efanov V.S., Prokopenko A.N., Ovchinnikov A.V., et al. Erosion resistance of helicopter GTE compressor blades with different types of coatings. *Vestnik dvigatelestroeniya*, 2017, no. 1, pp. 120–123 (in Russ.).
- [9] Nochovnaya N.A., Nikitin Ya.Yu. The current state of the question in the field of cleaning of the compressor GTE from operational pollution (review). *Trudy VIAM* [Proceedings of VIAM], 2017, no. 3 (in Russ.). DOI: <https://dx.doi.org/10.18577/2307-6046-2017-0-3-5-5>
- [10] Liu Y., Ravichandran R., Chen K., et al. Application of machine learning to solid particle erosion of aps-TBC and EB-PVD TBC at elevated temperatures. *Coatings*, 2021, vol. 11, no. 7, art. 845. DOI: <https://doi.org/10.3390/coatings11070845>
- [11] Bahrainian S., Bakhshesh M., Hajidavalloo E., et al. A novel approach for solid particle erosion prediction based on Gaussian Process Regression. *Wear*, 2020, vol. 466–467, art. 203549. DOI: <https://doi.org/10.1016/j.wear.2020.203549>
- [12] Zahedi P., Parvande S., Asgharpour A., et al. Random forest regression prediction of solid particle Erosion in elbows. *Powder Technol.*, 2018, vol. 338, pp. 983–992. DOI: <https://doi.org/10.1016/j.powtec.2018.07.055>
- [13] Giorgi M.G., Campilongo S., Ficarella A. A diagnostics tool for aero-engines health monitoring using machine learning technique. *Energy Procedia*, 2018, vol. 148, pp. 860–867. DOI: <https://doi.org/10.1016/j.egypro.2018.08.109>
- [14] Chai T., Draxler R.R. Root mean square error (RMSE) or mean absolute error (MAE)? — arguments against avoiding RMSE in the literature. *Geosci. Model Dev.*, 2014, vol. 7, no. 3, pp. 1247–1250. DOI: <https://doi.org/10.5194/gmd-7-1247-2014>
- [15] Joshuva A., Sugumaran V. A machine learning approach for condition monitoring of wind turbine blade using autoregressive moving average (ARMA) features through vibration signals: a comparative study. *Prog. Ind. Ecol.*, 2018, vol. 12, no. 1-2, pp. 14–34. DOI: <https://doi.org/10.1504/PIE.2018.095867>
- [16] Enríquez Zárate J., Gómez López M.A., Carmona Troyo J.A. Analysis and detection of erosion in wind turbine blades. *Math. Comput. Appl.*, 2022, vol. 27, no. 1, art. 5. DOI: <https://doi.org/10.3390/mca27010005>
- [17] Reid L., Moore R.D. Design and overall performance of four highly loaded, high-speed inlet stages for an advanced high-pressure-ratio core compressor. NASA report NASA-TP-1337. NASA Lewis Research Center, 1978.

- [18] Pedregosa F, Varoquaux G., Gramfort A., et al. Scikit-learn: machine learning in Python. *J. Mach. Learn. Res.*, 2011, vol. 12, pp. 2825–2830.
- [19] Denton J.D. Lessons from rotor 37. *J. of Therm. Sc.*, 1997, vol. 6, no. 1, pp. 1–13.
DOI: <https://doi.org/10.1007/s11630-997-0010-9>
- [20] Blinov V.L., Deryabin G.A., Zubkov I.S. Classification of the gas path erosion level of the insulated stage of the axial compressor. *Energeticheskie sistemy* [Energy Systems], 2022, vol. 7, no. 1, pp. 8–18 (in Russ.).
- [21] Dvirnyk Y., Pavlenko D., Przysowa R. Determination of serviceability limits of a turboshaft engine by the criterion of blade natural frequency and stall margin. *Aerospace*, 2019, vol. 6, no. 12. DOI: <https://doi.org/10.3390/aerospace6120132>
- [22] Vogel A., Durant A., Cassiani M., et al. Simulation of volcanic ash ingestion into a large aero engine: particle–fan interactions. *J. Turbomach.*, 2019, vol. 141, no. 1, art. 011010. DOI: <https://doi.org/10.1115/1.4041464>
- [23] Potapov V.A., Sanko A.A. Performance simulation of multi-stage axial-flow compressor of turbo-shaft engine with account for erosive wear nonlinearity of its blades. *Nauchnyy Vestnik MGTU GA* [Civil Aviation High Technologies], 2020, vol. 23, no. 5, pp. 39–53 (in Russ.). DOI: <https://doi.org/10.26467/2079-0619-2020-23-5-39-53>
- [24] Lever J., Krzywinski M., Altman N. Classification evaluation. *Nat. Methods*, 2016, vol. 13, no. 8, pp. 603–604. DOI: <https://doi.org/10.1038/nmeth.3945>
- [25] Han H., Guo X., Yu H. Variable selection using mean decrease accuracy and mean decrease gini based on random forest. *IEEE ICSESS*, 2016, pp. 219–224.
DOI: <https://doi.org/10.1109/ICSESS.2016.7883053>
- [26] Lix L.M., Keselman J.C., Keselman H.J. Consequences of assumption violations revisited: a quantitative review of alternatives to the one-way analysis of variance *F* test. *Rev. Educ. Res.*, 1996, vol. 66, no. 4, pp. 579–619.
DOI: <https://doi.org/10.3102/00346543066004579>

Blinov V.L. — Cand. Sc. (Eng.), Assoc. Professor, Department of Turbines and Engines, UrFU (Mira ul. 19, Ekaterinburg, 620002 Russian Federation).

Deryabin G.A. — Post-Graduate Student, Engineer, Department of Turbines and Engines, UrFU (Mira ul. 19, Ekaterinburg, 620002 Russian Federation).

Zubkov I.S. — Post-Graduate Student, Department of Turbines and Engines, UrFU (Mira ul. 19, Ekaterinburg, 620002 Russian Federation).

Please cite this article in English as:

Blinov V.L., Deryabin G.A., Zubkov I.S. Machine learning introduction to classify the erosive wear degree of the compressor stage blades. *Herald of the Bauman Moscow State Technical University, Series Mechanical Engineering*, 2023, no. 4 (147), pp. 88–105 (in Russ.). DOI: <https://doi.org/10.18698/0236-3941-2023-4-88-105>