

УДК 621.452.32:524.3-17

doi: 10.18698/0536-1044-2019-11-75-85

Способы создания функциональных моделей деталей газотурбинных двигателей с использованием численного моделирования и алгоритмов машинного обучения на примере диска турбины

С.В. Резник¹, Д.В. Сапронов^{1,2}, Б.Е. Васильев^{1,2}, А.В. Семенов²

¹ МГТУ им. Н.Э. Баумана

² ФГУП «ЦИАМ им. П.И. Баранова»

Methods of Creating Functional Models of Gas Turbine Engine Parts by Means of Numerical Modeling and Machine Learning Algorithms Using a Turbine Disk as an Example

S.V. Reznik¹, D.V. Sapronov^{1,2}, B.E. Vasiliev^{1,2}, A.V. Semenov²

¹ Bauman Moscow State Technical University

² Federal State Unitary Enterprise — Baranov Central Institute of Aviation Motors CIAM

Каждый авиационный газотурбинный двигатель имеет конструктивно-компоновочные и технологические особенности, что влияет на его ресурс. Для учета всех факторов, влияющих на ресурс двигателя, требуется большой объем вычислений. В связи с этим актуальна разработка функциональных моделей, представляющих собой виртуальные образы основных деталей каждого двигателя и содержащих информацию об их геометрии, параметрах нагружения и характеристиках. Эти модели должны выражать связь между множеством параметров, измеряемых или вычисляемых во время полета, с расчетными значениями циклической долговечности основных деталей. В последнее время для решения подобных задач применяют методы машинного обучения. Их особенность — обучение в процессе анализа множества решений при различных параметрах. Рассмотрен подход, позволяющий создавать функциональные модели элементов газотурбинных двигателей на основе численного моделирования теплонапряженного состояния и алгоритмов машинного обучения.

Ключевые слова: газотурбинный двигатель, диск турбины, функциональная модель, машинное обучение

Each aircraft gas turbine engine has design, layout and technological features that affect its operational life. To take into account all the factors that affect the operational life of the engine, a large amount of calculations is required. In this regard, it is important to develop functional models that represent virtual images of the main parts of each engine and contain information about their geometry, loading parameters and characteristics. These models should express the relationship between the many parameters measured and calculated during flight with the calculated values of the cyclic durability of the main engine parts. In recent years, machine learning has been used to solve such problems. The essence of this method is in training in the process of analyzing a variety of solutions under different parameters. This paper presents an approach that allows creating functional models of gas turbine engine elements using numerical modeling of the heat-stressed state and machine learning algorithms.

Keywords: gas turbine engine, turbine disk, functional model, machine learning

Современные авиационные газотурбинные двигатели (ГТД) являются крайне сложными техническими системами. Эксплуатация большинства двигателей третьего и четвертого поколений ведется по фиксированному ресурсу. Ресурс подтверждают на основе результатов стендовых эквивалентно-циклических испытаний и (или) расчетных оценок долговечности и трещиностойкости основных деталей.

Задача о полном расходовании ресурсных возможностей может быть решена при эксплуатации по техническому состоянию или технической надежности [1–4]. Здесь на первый план выходят проблемы внедрения эффективной системы диагностики и учета повреждаемости деталей. Комплексная диагностика позволит проводить трендовый анализ основных параметров ГТД, а также определять вероятность отказа отдельных элементов и требуемые интервалы контроля состояния.

Чтобы правильно учесть повреждаемость деталей, следует в каждый момент полета регистрировать параметры, необходимые для расчетов. При этом надо иметь динамическую модель ГТД, модели для определения теплового, напряженно-деформированного состояний и накопления повреждений.

Цель работы — совершенствование методов прогнозирования циклической долговечности основных деталей турбомашин.

На первом этапе предлагается автоматизировать процесс построения конечно-элементной модели детали, приложения граничных условий и вычисления циклической долговечности/повреждаемости.

На втором этапе следует провести расчет при возможных сочетаниях параметров конструкции, определить критические параметры (наиболее сильно влияющие на расчетное значение циклической долговечности) и диапазон их изменения при эксплуатации.

Параллельно необходимо убедиться в возможности диагностики критических параметров в эксплуатации. Если этого сделать нельзя, то отдельную задачу представляет собой поиск диагностируемых параметров, имеющих высокую степень корреляции с искомыми, и построение регрессионной зависимости.

На третьем этапе надо создать математическую модель, связывающую расчетное значение циклической долговечности/повреждаемости с критическими параметрами. Для построения такой модели предлагается исполь-

зовать алгоритмы машинного обучения с учителем (supervised learning). Эти алгоритмы автоматизируют процесс решения задачи посредством обобщения исходной информации, представляющей собой многомерные массивы данных.

В качестве тестового примера рассмотрен диск турбины авиационного ГТД, являющейся особо важной деталью, так как его разрушение может привести к катастрофическим последствиям.

Разработка параметризованной модели диска турбины. Двухмерная осесимметричная параметризованная модель диска турбины с пятнадцатью геометрическими параметрами приведена на рис. 1, а. Модель реализована в среде ANSYS с помощью встроенного языка программирования APDL. В качестве граничных условий заданы следующие нагрузки (рис. 1, б): угловая скорость вращения ω_y и линейное распределение температур от значения T_1 в ступице до значения T_2 в ободной части диска. Центральный узел ступицы закреплен по осевому направлению ($U_y = 0$).

При построении сетки выбран осесимметричный тип элементов PLANE182. Инерционное воздействие от замковой части диска и лопаток учитывалось в виде распределенного давления p , приложенного к ободной части диска,

$$p = \frac{k(\rho_d V_d \omega_y^2 R_{ЦТд} + \rho_l V_l \omega_y^2 R_{ЦТл})}{2\pi r h},$$

где k — число лопаток и замковых выступов диска; ρ_d , V_d , $R_{ЦТд}$ и ρ_l , V_l , $R_{ЦТл}$ — соответственно плотность, объем, центр тяжести (ЦТ) замковой части диска и лопатки; r и h — радиус и толщина ободной части диска.

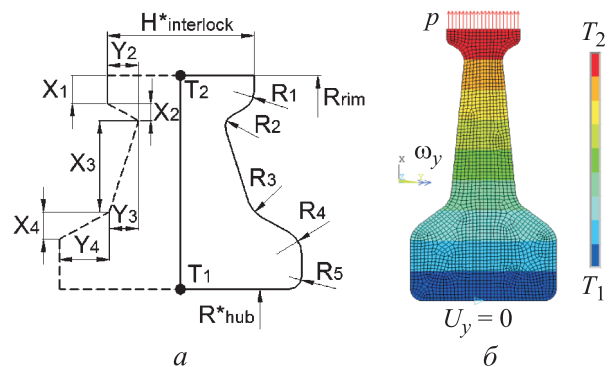


Рис. 1. Параметризованная модель диска турбины (а) и граничные условия для нее (б)

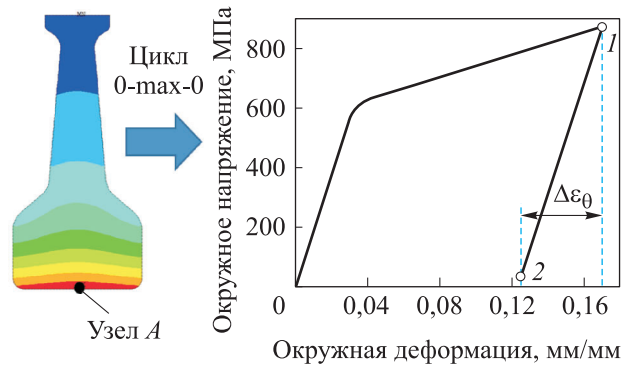


Рис. 2. Определение размаха окружных деформаций:

1 — нагрузка узла А; 2 — разгрузка узла А

Диск выполнен из жаропрочного никелевого сплава плотностью $\rho = 8200 \text{ кг/м}^3$. Принято, что при увеличении температур с 20 до 650 °С модуль упругости E изменяется от 200 до 170 ГПа, предел прочности σ_b — от 1100 до 950 МПа, относительное сужение поперечного сечения ψ — от 0,16 до 0,18; коэффициент Пуассона $\mu = 0,3$; коэффициент линейного термического расширения $\alpha = 1,2 \cdot 10^{-5} \text{ К}^{-1}$.

Предполагалось, что характеристики материала диска соответствуют модели полилинейного кинематического упрочнения Multilinear Kinematic Hardening, учитывающей эффект Баушингера, с критерием возникновения пластических деформаций Мизеса [5–7]. Для упрощения использована билинейная модель материала. В диапазоне температур 20...650 °С касательный

модуль упругости $E_T = 20...15 \text{ ГПа}$, а предел пропорциональности $\sigma_{\text{пц}} = 650...550 \text{ МПа}$.

Во внутреннем цикле программного кода определялся размах значений окружных деформаций $\Delta\epsilon_\theta$ для нагружения 0-тах-0 в узле А (рис. 2). Проводилось два последовательных расчета: при нагрузке (точка 1) с параметрами $\omega_y = 2150...2350 \text{ рад/с}$, $T_1 = 300...350 \text{ °С}$, $T_2 = 600...650 \text{ °С}$, $p(\omega_y)$ и при разгрузке (точка 2) с $\omega_y = 0$, $T_1 = 20 \text{ °С}$, $T_2 = 25 \text{ °С}$, $p(\omega_y) = 0$. Во внешнем цикле генерировались n вариантов нагружений 0-тах-0 с произвольным набором параметров; в текстовый файл записывались значения ω_{yi} , T_{1i} , T_{2i} и $\Delta\epsilon_\theta$.

Подготовка данных для машинного обучения.

Получен набор данных для $n = 1000$. При дальнейшей работе с этими данными использована программная среда Python. Для решения нелинейных и трансцендентных уравнений написан вспомогательный программный код, основанный на методе половинного деления [8, 9]. Расчетная циклическая долговечность N определялась с помощью этого кода и формулы Мэнсона [10, 11] (рис. 3)

$$\Delta\epsilon_\theta = \left(\ln \frac{1}{1-\psi} \right)^{0,6} N^{-0,6} + \frac{3,5\sigma_b}{E} N^{-0,12}. \quad (1)$$

На рис. 4 показаны гистограммы плотности распределения исследуемых параметров ω_y , T_1 ,

```
In [28]: import numpy as np
         from numpy import sign

         def rootsearch(f,a,b,dx):
             x1=a; f1=f(a)
             x2=a+dx; f2=f(x2)
             while sign(f1)!=sign(f2):
                 if x1>=b: return None, None
                 x1=x2; f1=f2
                 x2=x1+dx; f2=f(x2)
                 x=(x1+x2)/2
             else:
                 return x

In [29]: a=[]
         for j in range(c):
             def f(x): return df.iloc[j,19]*x**-0.6+df.iloc[j,20]*x**-0.12-df.iloc[j,7]
             a.append(rootsearch(f,1,100000,10))

In [30]: df['N']=a
```

Рис. 3. Фрагмент кода для решения уравнения (1) относительно циклической долговечности N




Рис. 4. Плотности распределения параметров:

a — частоты вращения ω_y ($p_value_n = 1,78 \cdot 10^{-17}$); *б* — температуры T_1 ($p_value_n = 1,07 \cdot 10^{-17}$);
в — температуры T_2 ($p_value_n = 3,91 \cdot 10^{-17}$); *г* — циклической долговечности N ($p_value_n = 3,03 \cdot 10^{-15}$)

T_2 и N . Дополнительно проведены тесты Шапиро — Уилка на нормальность распределения данных и определены околонулевые значения p_value_n (нулевая гипотеза о нормальности распределения). Использована библиотека Python-stats [12, 13].

Уровень значимости α принят равным 0,05. Как видно из полученных гистограмм и околонулевых значений p_value_n , распределения данных сильно отличаются от нормальных

Коэффициенты корреляции Спирмена и p -значения

Параметры	ω_y	T_1	T_2	N
ω_y	1,00	-0,01	0,01	-0,94
	0	0,72	0,76	0
T_1	-0,01	1,00	0,01	0,18
	0,72	0	0,70	$4,6 \cdot 10^{-9}$
T_2	0,01	0,01	1,00	-0,27
	0,76	0,70	0	$8,8 \cdot 10^{-19}$
N	-0,94	0,18	-0,27	1,00
	0	$4,6 \cdot 10^{-9}$	$8,8 \cdot 10^{-19}$	0

Примечание. Синим цветом обозначены коэффициенты Спирмена k_s , красным — p -значения p_value_s .

(Гаусса). Поэтому для определения корреляционных зависимостей выбраны коэффициенты Спирмена. В этом случае нулевая гипотеза — отсутствие корреляции между величинами.

Как видно из приведенных данных, больше всего на значение расчетной циклической долговечности влияет угловая скорость вращения ω_y , затем температура в ободной части T_2 и меньше всего — температура в ступице T_1 . Знак минус указывает на то, что при увеличении одной величины уменьшается вторая. Ввиду малых значений p_value_s нулевую гипотезу об отсутствии корреляции между расчетной циклической долговечностью N и параметрами ω_y , T_1 , T_2 отвергаем. По одной из классификаций при значениях коэффициента корреляции менее 0,3 связь между параметрами следует считать слабой. Однако в работе принято решение оставить параметры температуры при дальнейшем исследовании.

Далее рассмотрены предиктивные модели [14–16], позволяющие находить значение цик-

лической долговечности N с помощью параметров ω_y , T_1 и T_2 . Предполагается, что эти параметры будут записываться в процессе эксплуатации, а значение N будет определяться автоматически.

Оценка качества моделей выполнена по двум критериям. Первый критерий ϵ определялся как среднее отклонение значений N тестовой выборки от значений, рассчитанных по построенной модели [17]. Второй критерий — коэффициент детерминации

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

где y_i и \hat{y}_i — фактическое и расчетное значения исследуемой переменной; \bar{y} — среднее фактическое значение переменной.

Из общей выборки данных $n = 1000$ на обучение выделено $n_{train} = 750$, а на проверку $n_{test} = 250$. Расчеты проведены в среде Python с использованием библиотеки sklearn.

Построение предиктивных моделей циклической долговечности. Метод K -ближайших соседей (K -Neighbors). Данный алгоритм относит исследуемый объект к тому классу, которому принадлежат K ближайших обучающих объектов. Обучение сводится к запоминанию выборки данных с входными признаками ω_y , T_1 , T_2 и соответствующими им значениями N .

Для определения расстояния d между параметрами p и q использована евклидова метрика

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}.$$

Расчеты проведены в модуле sklearn-KNeighborsRegressor. Для получения оптимальной модели последовательно изменялось количество соседей K (рис. 5). Выбран вариант с $K = 8$. При этом получены следующие значения выбранных критериев: для обучающей выборки $\epsilon_{train} = 318$ циклов (ц.) и $R_{train}^2 = 0,99226$, для тестовой выборки $\epsilon_{test} = 371$ ц. и $R_{test}^2 = 0,99433$.

Линейные модели для регрессии. Линейные модели дают прогноз, используя линейную функцию входных признаков. Линейная модель в общем виде определяется выражением

$$\hat{y} = w[0]x[0] + w[1]x[1] + \dots + w[p]x[p] + b, \quad (2)$$

где \hat{y} — прогноз, получаемый в модели; $w[j]$, b — параметры модели, оцениваемые в ходе обучения, $j = 0, 1, \dots, p$; $x[i]$ — признаки для i -х точек данных.

Расчеты проведены в модуле sklearn-LinearRegression. В первом случае коэффициенты выражения (2) определялись из условия минимизации среднеквадратической ошибки (суммы квадратов разностей) между спрогнозированными и фактическими значениями N на обучающей выборке. Получено следующее выражение для определения циклической долговечности:

$$N = -104\omega_y + 90T_1 - 131T_2 + 313310.$$

Эта формула имеет хорошую наглядность. Например, если увеличить угловую скорость вращения на единицу при неизменных значениях остальных параметров, то циклическая долговечность уменьшится на 104.

При этом получены следующие значения выбранных критериев: для обучающей выборки $\epsilon_{train} = 776$ ц. и $R_{train}^2 = 0,97756$, для тестовой выборки $\epsilon_{test} = 742$ ц. и $R_{test}^2 = 0,97969$.

Также проведены расчеты для моделей гребневой линейной регрессии (ridge) и линейной регрессии Лассо (Lasso). В этих моделях дополнительно введено условие минимизации значений коэффициентов $w[j]$. Это означает, что каждый из признаков должен иметь как можно меньшее влияние на результат. Однако использование перечисленных моделей не повлияло существенным образом на результат.

Деревья решений. Такие алгоритмы выстраивают иерархию правил «если — то», приводя-

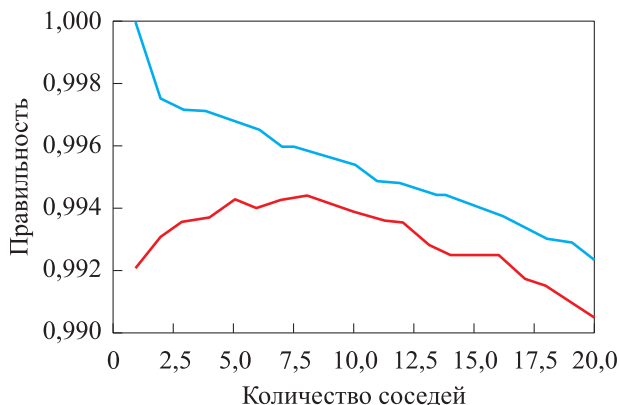


Рис. 5. Настройка алгоритма K-Neighbors для обучающей (—) и тестовой (—) выборки

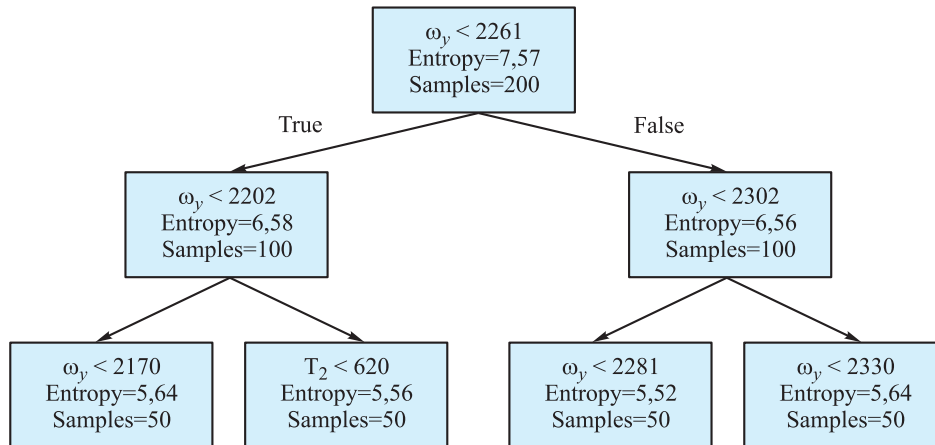


Рис. 6. Графическое представление дерева решений

щую к конкретному результату. Каждый узел дерева представляет собой либо вопрос, либо терминальный узел (лист) с ответом. Ребра соединяют вышестоящие узлы с нижестоящими.

В математике это соответствует изменению количества информации, основанного на понятии энтропии. Параметр энтропии Шеннона для системы с P возможными состояниями вычисляется как

$$S = -\sum_{k=1}^P p_k \log_2 p_k,$$

где p_k — вероятность нахождения системы в k -м состоянии.

Уменьшение энтропии называют приростом информации. В случае разбиения выборки по признаку Q прирост информации определяется из соотношения

$$IG(Q) = S_0 - \sum_{k=1}^q \frac{N_k}{N} S_k,$$

где S_0 — параметр энтропии Шеннона до разбиения выборки на группы; q — число групп после разбиения; N_k — число элементов выборки, у которых признак Q имеет k -е значение; S_k — параметр энтропии Шеннона для каждой группы после разбиения.

Если параметр S равен нулю, то все объекты исходного набора принадлежат к одному классу. Если он не равен нулю, то проводится поиск предиката, способного обеспечить наибольшее значение прироста информации IG .

Чем больше терминальных узлов в дереве, тем больше правильных ответов на тестовой выборке. Это может привести к переобучению модели при наличии точек-выбросов данных.

Переобучение — это явление, характеризуемое очень высокой точностью модели на обучающей выборке и крайне низкой на тестовой. Чтобы избежать переобучения, необходимо рационально проводить остановку построения дерева при ограниченном числе разделений \max_depth . Расчеты проведены в модуле `sklearn-DecisionTreeRegressor`.

Схема построения дерева при числе обучающих параметров $n_{train} = 200$ и ограничении высоты дерева $\max_depth = 2$ показана на рис. 6, где Entropy — энтропия, Samples — число обучающих параметров. Значения частоты вращения указаны в рад/с.

При $n_{train} = 750$, $n_{test} = 250$ и $\max_depth = 10$ получены следующие значения выбранных критериев: на обучающей выборке $\epsilon_{train} = 2$ ц. и $R_{train}^2 = 0,99960$, на тестовой выборке $\epsilon_{test} = 786$ ц. и $R_{test}^2 = 0,97665$.

Более эффективными считаются алгоритмы случайного леса и градиентного бустинга, создаваемые на базе единичных деревьев решений. Использование множества деревьев решений различной высоты позволяет снизить степень переобучения путем усреднения результатов.

Для реализации алгоритма случайного леса использован модуль `sklearn-RandomForestRegressor`. Варьировалось число деревьев при случайном значении высоты каждого (с ограничением $\max_depth < 10$). Результаты расчетов показаны на рис. 7.

Анализ расчетных данных позволяет утверждать, что данный алгоритм существенно улучшает результаты на тестовой выборке при количестве деревьев более 10. Получены следующие значения выбранных критериев: на обучающей выборке $\epsilon_{train} = 150$ ц. и $R_{train}^2 = 0,99908$, на тестовой выборке $\epsilon_{test} = 390$ ц. и $R_{test}^2 = 0,99405$.

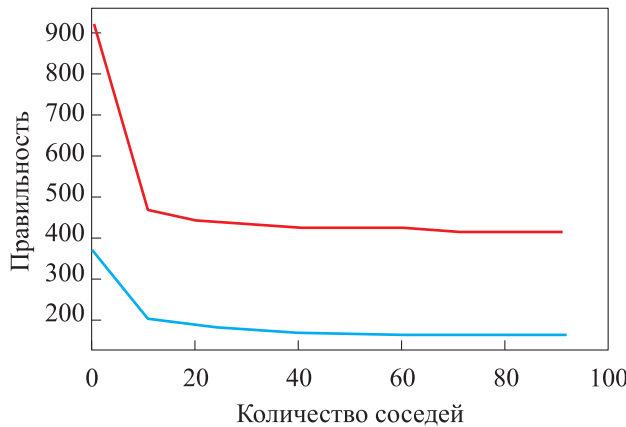


Рис. 7. Настройка алгоритма RandomForest для обучающей (—) и тестовой (—) выборок




Рис. 8. Настройка алгоритма Gradient Boosting для обучающей (—) и тестовой (—) выборок

Более совершенный алгоритм — градиентный бустинг деревьев регрессии, где, как и в методе случайного леса, постепенно добавляется все большее количество деревьев. При этом параметры каждого нового дерева выбираются так, чтобы улучшить модель.

При решении задачи минимизации квадратичного функционала Φ итоговый алгоритм для определения искомой функции a_N , зависящей от x , можно представить в виде суммы базовых моделей (weak learners) $b_n(x)$:

$$\Phi = \frac{1}{2} \sum_{m=1}^l [a(x_m) - y_m]^2 \rightarrow \min_a, \quad a_N(x) = \sum_{n=1}^N b_n(x),$$

где $a(x_m)$ — значения искомой функции в точках x_m , где m принимает значения от 1 до выбираемого l .

Первый базовый алгоритм

$$b_1(x) = \arg \min_b \frac{1}{2} \sum_{m=1}^l [b(x_m) - y_m]^2.$$

Расстояние от первого базового алгоритма до истинных значений

$$s_m^{(1)} = y_m - b_1(x_m).$$

Второй базовый алгоритм строится так, чтобы его ответы были как можно ближе к расстоянию $s_m^{(1)}$:

$$b_2(x) = \arg \min_b \frac{1}{2} \sum_{m=1}^l [b(x_m) - s_m^{(1)}]^2,$$

и так далее.

Чтобы избежать быстрого переобучения модели, необходимо выполнить процедуры сокращения шага:

$$a_N(x) = a_{N-1}(x) + \eta b_N(x),$$

где $a_{N-1}(x)$ — искомая функция на шаге решения « $N-1$ »; η — скорость обучения; $b_N(x)$ — базовая модель на шаге решения « N ».

Подобный алгоритм реализован в модуле sklearn-GradientBoostingRegressor. Помимо высоты и количества деревьев, в нем есть еще один существенный параметр — learning_rate (аналог параметра η), который контролирует скорость улучшения модели и является безразмерной величиной. При расчетах варьировалась скорость обучения при высоте каждого дерева max_depth = 2 и количестве деревьев, равном 800. Результаты расчетов приведены на рис. 8.

Анализа расчетных данных показал, что данный алгоритм позволяет существенно улучшить результаты на тестовой выборке при скорости обучения, равной 0,12. На обучающей выборке $\epsilon_{train} = 83$ ц. и $R_{train}^2 = 0,99974$, на тестовой выборке $\epsilon_{test} = 239$ ц. и $R_{test}^2 = 0,99768$.

Нейронные сети. Понятие искусственной нейронной сети предложили в 1943 г. ученые Уоррен Мак-Каллок и Уолтер Питтс. Аналогом такой модели является работа нервной клетки нейрона: когда суммарный заряд внутри нее, получаемый от отростков — дендритов, превосходит некоторый порог активации, клетка переходит в активное состояние и генерирует электрический импульс, распространяющийся по длинному отростку — аксону, в конце которого происходит взаимодействие со следующей клеткой.

В машинном обучении нейронная сеть — это обобщение линейных моделей с выполнением нескольких этапов обработки данных. Простейшая модель нейронной сети с одним скрытым слоем состоит из входных признаков




Рис. 9. Схема перцептрона с одним скрытым слоем




Рис. 10. Настройка алгоритма MLPRegressor для обучающей (—) и тестовой (—) выборок

x_i , скрытых элементов h_j и выходного значения Y (рис. 9).

Сначала вычисляют параметры скрытого слоя h_j как разность взвешенной суммы входных признаков и пороговых значений θ . Затем к полученным значениям h_j применяют функцию активации σ , после чего определяют выходное значение Y через взвешенные суммы параметров h_j :

$$h_j = \sigma \left(\sum_{i=0}^3 w_{ij} x_i - \theta \right) \rightarrow Y = \sum_{j=0}^2 v_j h_j,$$

где w_{ij} — коэффициент между каждым входом и скрытым элементом; v_j — коэффициент между каждым скрытым элементом и выходом.

В качестве функции активации на практике широкое применение получили следующие функции:

- пороговая функция Хевисайда $\theta(z) = [z > 0]$;
- сигмоидная функция $\sigma(z) = (1 + e^{-z})^{-1}$;
- гиперболический тангенс $\text{th}(z) = 2\sigma(2z) - 1$;
- логарифмическая функция $L(z) = \ln(z + (z^2 + 1)^{1/2})$;
- гауссовская функция $G(z) = \exp(-z^2/2)$;
- линейная функция z .

Модель многослойного перцептрона (multi-layer perceptron) реализована в модуле sklearn-MLPRegressor. В этой модели можно варьировать числа скрытых слоев и элементов в них. В качестве функции активации использована сигмоидная функция (предварительные расчеты показали ее преимущество перед другими функциями). После ряда манипуляций получена структура перцептрона с тремя элементами в первом скрытом слое и с пятьюдесятью семью элементами во втором скрытом слое (рис. 10).

Получены следующие значения выбранных критериев: для обучающей выборки $\epsilon_{train} = 172$ ц. и $R_{train}^2 = 0,99874$, для тестовой выборки $\epsilon_{test} = 165$ ц. и $R_{test}^2 = 0,99888$. Таким образом, по сравнению с другими рассмотренными моделями алгоритм MLPRegressor после настройки дает наилучшее качество предсказания на тестовой выборке.

Создание функциональной модели диска турбины. Предположим, что после 1000 полетных циклов 0-тах-0 в реальной эксплуатации угловая скорость вращения диска турбины снизится с 2300 до 2200 рад/с, температура в ободной части повысится с 610 до 640 °С, а в ступице — с 300 до 320 °С.

В качестве примера примем, что все ранее перечисленные параметры изменяются линейно. Исследуем изменение повреждаемости в




Рис. 11. Значения повреждаемости в каждом цикле Π , рассчитанные разными методами:

1 и 2 — в среде ANSYS по формуле (1) без учета и с учетом снижения частоты вращения и повышения температуры; 3 и 4 — с использованием предиктивных алгоритмов GradientBoosting и MLPRegressor

каждый момент времени Π_i и получим суммарную оценку

$$\Pi_i = \frac{1}{N_i} \rightarrow \Pi_{\Sigma} = \sum_{i=1}^{1000} \Pi_i.$$

На рис. 11 приведены значения повреждаемости в каждом цикле Π (от 1 до 1000) при прямом расчете в среде ANSYS по формуле (1) и при использовании двух алгоритмов, показавших наибольшую эффективность: GradientBoosting и MLPRegressor.

При расчете в среде ANSYS без учета снижения частоты вращения и повышения температуры суммарная повреждаемость (за 1000 ц.) $\Pi_{\Sigma} = 0,0485$, а при аналогичном расчете с учетом изменения этих параметров $\Pi_{\Sigma} = 0,0418$. Суммарные повреждаемости, вычисленные с использованием предиктивных алгоритмов GradientBoosting и MLPRegressor, составили 0,0416 и 0,0419 соответственно.

Выводы

1. В случае учета эксплуатационных особенностей (изменения угловой скорости вращения и температур) значения суммарной повреждаемости могут различаться более чем на 16 %.

2. Значения суммарной повреждаемости, определенные с помощью алгоритмов GradientBoosting и MLPRegressor, отличаются от значения, полученного прямым расчетом в среде ANSYS, на 0,48 и 0,24 % соответственно.

3. Предиктивные алгоритмы имеют хорошие перспективы для вычисления повреждаемости в режиме онлайн.

4. При дальнейших исследованиях в алгоритм обучения можно включить отклонение геометрических параметров и свойств материала (что легко сделать благодаря параметризованной модели диска). Таким образом, будет создана математическая модель, универсально пригодная для учета индивидуальных технологических и эксплуатационных особенностей каждого диска всей серии.

Литература

- [1] Иноземцев А.А., Сандрацкий В.Л. *Газотурбинные двигатели*. Пермь, ОАО «Авиадвигатель», 2006. 1204 с.
- [2] Елисеев Ю.С., Крымов В.В., Малиновский К.А., Попов В.Г. *Технология эксплуатации, диагностики и ремонта газотурбинных двигателей*. Москва, Высшая школа, 2002. 355 с.
- [3] Ножницкий Ю.А. Современные методы обеспечения прочностной надежности деталей авиационных двигателей. В сб. работ ФГУП «ЦИАМ им. П.И. Баранова», Москва, ТОРУС ПРЕСС, 2010. 456 с.
- [4] Резник С.В. Актуальные проблемы проектирования, производства и испытания ракетно-космических композитных конструкций. *Актуальные проблемы развития ракетно-космической техники и систем вооружений*. Тр. МГТУ им. Н.Э. Баумана, 2013, № 606, с. 295–311.
- [5] Малинин Н.Н. *Прикладная теория пластичности и ползучести*. Москва, Машиностроение, 1975. 400 с.
- [6] Lee Y.-L., Barkey M.E., Kang H.-T. *Metal fatigue analysis handbook. Practical Problem-Solving Techniques for Computer-Aided Engineering*. Boston, Elsevier, 2012. 580 p.
- [7] Collins J.A. *Failure of Materials in Mechanical Design*. New York, John Wiley & Sons, 1981. 622 p.
- [8] Формалев В.Ф., Ревизников Д.Л. *Численные методы*. Москва, Физматлит, 2004. 400 с.
- [9] Johansson R. *Numerical Python*. New York, Apress, 2015. 481 p.
- [10] Биргер И.А., Шорр Б.Ф., Иосилевич Г.Б. *Расчет на прочность деталей машин*. Москва, Машиностроение, 1993. 640 с.
- [11] Серенсен С.В. *Исследования малоциклового прочностии при высоких температурах*. Москва, Наука, 1975. 128 с.
- [12] Haslwanter T. *An Introduction to Statistics with Python*. Berlin, Springer, 2015. 278 p.
- [13] Downey A.B. *Think Stats*. Sebastopol, O'Reilly Media publ., 2015. 206 p.
- [14] McKinney W. *Python for Data Analysis*. Sebastopol, O'Reilly Media publ., 2015. 482 p.

- [15] Andreas C.M., Guido S. *Introduction to Machine Learning with Python*. Sebastopol, O'Reilly Media publ., 2017. 392 p.
- [16] Brink H., Joseph W.R., Fetherolf M. *Real-World Machine Learning*. Shelter Island, Manning, 2016. 427 p.
- [17] Степнов М.Н., Шаврин А.В. *Статистические методы обработки результатов механических испытаний*. Москва, Машиностроение, 2005. 399 с.

References

- [1] Inozemtsev A.A., Sandratskiy V.L. *Gazoturbinnyye dvigateli* [Gas turbine engines]. Perm, Aviadvigatel' publ., 2006. 1204 p.
- [2] Eliseyev Yu.S., Krymov V.V., Malinovskiy K.A., Popov V.G. *Tekhnologiya ekspluatatsii, diagnostiki i remonta gazoturbinnyykh dvigateley* [Technology of operation, diagnostics and repair of gas turbine engines]. Moscow, Vysshaya shkola publ., 2002. 355 p.
- [3] Nozhnitskiy Yu.A. Modern methods for ensuring the strength reliability of aircraft engine parts. *V sbornike rabot FGUP «TSIAM im. P.I. Baranova»* [In the collection of works of FSUE "TsIAM them. P.I. Baranova"]. Moscow, TORUS PRESS publ., 2010. 456 p.
- [4] Reznik S.V. Actual problems of the design, production and testing of space rocket composite structures. *Aktual'nyye problemy razvitiya raketno-kosmicheskoy tekhniki i sistem vooruzheniy. Trudy MGTU im. N.E. Baumana* [Actual problems of the development of rocket and space technology and weapons systems. Proceedings of BMSTU]. 2013, no. 606, pp. 295–311.
- [5] Malinin N.N. *Prikladnaya teoriya plastichnosti i polzuchesti* [Applied Theory of Plasticity and Creep]. Moscow, Mashinostroyeniye publ., 1975. 400 p.
- [6] Lee Y.-L., Barkey M.E., Kang H.-T. *Metal fatigue analysis handbook. Practical Problem-Solving Techniques for Computer-Aided Engineering*. Boston, Elsevier, 2012. 580 p.
- [7] Collins J.A. *Failure of Materials in Mechanical Design*. New York, John Wiley & Sons, 1981. 622 p.
- [8] Formalev V.F., Reviznikov D.L. *Chislennyye metody* [Numerical methods]. Moscow, Fizmatlit publ., 2004. 400 p.
- [9] Johansson R. *Numerical Python*. New York, Apress, 2015. 481 p.
- [10] Birger I.A., Shorr B.F., Iosilevich G.B. *Raschet na prochnost' detaley mashin* [Strength calculation of machine parts]. Moscow, Mashinostroyeniye, 1993. 640 p.
- [11] Serensen S.V. *Issledovaniya malotsiklovoy prochnosti pri vysokikh temperaturakh* [High Cycle Strength Studies]. Moscow, Nauka publ., 1975. 128 p.
- [12] Haslwanter T. *An Introduction to Statistics with Python*. Berlin, Springer, 2015. 278 p.
- [13] Downey A.B. *Think Stats*. Sebastopol, O'Reilly Media publ., 2015. 206 p.
- [14] McKinney W. *Python for Data Analysis*. Sebastopol, O'Reilly Media publ., 2015. 482 p.
- [15] Andreas C.M., Guido S. *Introduction to Machine Learning with Python*. Sebastopol, O'Reilly Media publ., 2017. 392 p.
- [16] Brink H., Joseph W.R., Fetherolf M. *Real-World Machine Learning*. Shelter Island, Manning, 2016. 427 p.
- [17] Stepnov M.N., Shavrin A.V. *Statisticheskiye metody obrabotki rezul'tatov mekhanicheskikh ispytaniy* [Statistical methods for processing the results of mechanical tests]. Moscow, Mashinostroyeniye publ., 2005. 399 p.

Статья поступила в редакцию 07.10.2019

Информация об авторах

РЕЗНИК Сергей Васильевич — доктор технических наук, профессор, заведующий кафедрой «Ракетно-космические композитные конструкции». МГТУ им. Н.Э. Баумана (105005, Москва, Российская Федерация, 2-я Бауманская ул., д. 5, стр. 1, e-mail: sreznik@bmstu.ru).

САПРОНОВ Дмитрий Владимирович — кандидат технических наук, доцент кафедры «Ракетно-космические композитные конструкции». МГТУ им. Н.Э. Баумана; ведущий инженер. ФГУП «ЦИАМ им. П.И. Баранова» (111116, Москва, Российская Федерация, ул. Авиамоторная, д. 2, корп. 19, e-mail: dvsapronov@ciam.ru).

ВАСИЛЬЕВ Борис Евгеньевич — кандидат технических наук, начальник отдела. ФГУП «ЦИАМ им. П.И. Баранова»; доцент кафедры «Газотурбинные и нетрадиционные энергоустановки». МГТУ им. Н.Э. Баумана (105005, Москва, Российская Федерация, ул. 2-я Бауманская, д. 5, e-mail: bevasilev@ciam.ru).

СЕМЕНОВ Артем Васильевич — ведущий инженер. ФГУП «ЦИАМ им. П.И. Баранова» (111116, Москва, Российская Федерация, ул. Авиамоторная, д. 2, корп. 19, e-mail: avsemenov@ciam.ru).

Information about the authors

REZNIK Sergei Vasilievich — Doctor of Science (Eng.), Professor, Head of Department, Space-Rocket Composite Design. Bauman Moscow State Technical University (105005, Moscow, Russian Federation, 2nd Baumanskaya St., Bldg. 5, Block 1, e-mail: sreznik@bmstu.ru).

SAPRONOV Dmitrii Vladimirovich — Candidate of Science (Eng.), Associate Professor, Space-Rocket Composite Design Department; Lead Engineer. Federal State Unitary Enterprise — Baranov Central Institute of Aviation Motors CIAM (111116, Moscow, Russian Federation, Aviamotornaya St., Bldg. 2, e-mail: dvsapronov@ciam.ru).

VASILIEV Boris Evgenievich — Candidate of Science (Eng.), Head of Department. Federal State Unitary Enterprise — Baranov Central Institute of Aviation Motors CIAM; Associate Professor, Department of Gas Turbine and Non-Conventional Power Plants. Bauman Moscow State Technical University (105005, Moscow, Russian Federation, 2nd Baumanskaya St., Bldg. 5, Block 1, e-mail: b_vasilyev@ciam.ru).

SEMENOV Artem Vasilievich — Lead Engineer. Federal State Unitary Enterprise — Baranov Central Institute of Aviation Motors CIAM (111116, Moscow, Russian Federation, Aviamotornaya St., Bldg. 2, e-mail: avsemenov@ciam.ru).

Просьба ссылаться на эту статью следующим образом:

Резник С.В., Сапронов Д.В., Васильев Б.Е., Семенов А.В. Способы создания функциональных моделей деталей газотурбинных двигателей с использованием численного моделирования и алгоритмов машинного обучения на примере диска турбины. *Известия высших учебных заведений. Машиностроение*, 2019, № 11, с. 75–85, doi: 10.18698/0536-1044-2019-11-75-85

Please cite this article in English as:

Reznik S.V., Sapronov D.V., Vasiliev B.E., Semenov A.V. Methods of Creating Functional Models of Gas Turbine Engine Parts by Means of Numerical Modeling and Machine Learning Algorithms Using a Turbine Disk as an Example. *Proceedings of Higher Educational Institutions. Machine Building*, 2019, no. 11, pp. 75–85, doi: 10.18698/0536-1044-2019-11-75-85