

Андрианов И. К., Фролов Д. О.
I. K. Andrianov, D. O. Frolov

**МЕТОД ОПРЕДЕЛЕНИЯ НАИБОЛЕЕ ТЕРМОНАГРУЖЕННОЙ ОБЛАСТИ
НА ПОВЕРХНОСТИ ЛОПАТКИ ГАЗОТУРБИННОГО ДВИГАТЕЛЯ
С ИСПОЛЬЗОВАНИЕМ НЕЙРОННОЙ СЕТИ**

**METHOD FOR DETERMINING THE MOST THERMALLY LOADED AREA
ON THE SURFACE OF A GAS TURBINE ENGINE BLADE USING A NEURAL NETWORK**

Андрианов Иван Константинович – кандидат технических наук, доцент Комсомольского-на-Амуре государственного университета (Россия, Комсомольск-на-Амуре); 681013, г. Комсомольск-на-Амуре, пр. Ленина, 27. E-mail: ivan_andrianov_90@mail.ru.

Ivan K. Andrianov – PhD in Engineering, Associate Professor, Komsomolsk-na-Amure State University (Russia, Komsomolsk-on-Amur); 681013, Komsomolsk-on-Amur, Lenin Ave., 27. E-mail: ivan_andrianov_90@mail.ru.

Фролов Дмитрий Олегович – аспирант Комсомольского-на-Амуре государственного университета (Россия, Комсомольск-на-Амуре). E-mail: optcompanys@mail.ru.

Dmitriy O. Frolov – Postgraduate Student, Komsomolsk-na-Amure State University (Russia, Komsomolsk-on-Amur). E-mail: optcompanys@mail.ru.

Аннотация. В данной статье предложен метод для определения наиболее термонагруженной зоны на поверхности лопатки газотурбинного двигателя, омываемой высокотемпературной газовой средой, с применением нейронных сетей. Задача точного определения температурных пиков является ключевой для повышения долговечности работы лопаток газотурбинных двигателей, а также повышения эффективности работы систем охлаждения. В статье приводятся подходы к моделированию температурных распределений с использованием численных решений уравнений теплопроводности. Нейронная сеть, обученная на стандартизированных данных, показала высокую точность, сравнимую с результатами традиционных аналитических и численных методов. Анализ ошибок модели, а также исследование влияния гиперпараметров и структуры сети на точность предсказаний показали положительные результаты. Работы подтверждают потенциал применения методов машинного обучения для прогнозирования тепловых процессов в условиях высоких температур, характерных для эксплуатации турбин. В статье также рассматриваются практическое применение предложенной методики и перспективы её дальнейшего улучшения.

Summary. This article proposes a method for determining the most thermally loaded zone on the surface of a gas turbine engine blade washed by a high-temperature gas environment using neural networks. The task of accurately determining temperature peaks is key to increasing the durability of gas turbine engine blades, as well as increasing the efficiency of cooling systems. The article presents approaches to modeling temperature distributions using numerical solutions of heat conduction equations. A neural network trained on standardized data showed high accuracy comparable to the results of traditional analytical and numerical methods. Analyze error patterns and explore all hyperparameters and network structure to predict positive results. The work confirms the potential of using machine learning methods to predict thermal processes under high-temperature conditions typical for turbine operation. The article also discusses practical applications of the proposed methodology and prospects for its further improvement.

Ключевые слова: турбинная лопатка, тепловое нагружение, нейронные сети, прогнозирование температурного поля.

Key words: turbine blade, thermal loading, neural networks, temperature field prediction.

Исследование выполнено за счёт гранта Российского научного фонда № 22-79-10114 «Разработка системы диагностирования повреждений турбинных лопаток и способа оптимизации теплоотвода в условиях термической усталости» (<https://rscf.ru/project/22-79-10114/>).

Введение. Развитие современного турбомашиностроения связано с разработкой методов диагностирования усталостных трещин и снижения вероятности разрушения турбинных лопаток в процессе их развития. Сегодня проведён ряд исследований для обнаружения трещин в турбинных лопатках в нестационарных условиях [1–3]. Одним из подходов для исключения развития трещин в лопатках, подвергаемых тепловому и силовому воздействиям, является применение оптимизированных систем внутреннего охлаждения. Однако малоисследованным остаётся вопрос оптимизации таких систем. Актуальность данного исследования обусловлена тем, что точное определение наиболее нагруженных участков лопатки позволит оптимизировать работу системы охлаждения за счёт перераспределения подачи охлаждающей газовой среды, повысив эффективность теплоотвода в наиболее термонагруженных участках. Реализация неравномерного охлаждения позволит исключить нецелесообразный теплоотвод в менее нагруженных зонах.

Прогнозирование температурного распределения на поверхности лопаток турбин имеет ключевое значение для их долговечности и надёжности. Лопатки газотурбинного двигателя эксплуатируются при экстремальных температурах, и даже незначительные перегревы способны вызывать их повреждения или разрушение. Выявление участков максимальной температуры играет важную роль в мониторинге критичных зон и совершенствовании конструкции. В данной работе рассматривается разработка искусственной нейронной сети, способной точно определять максимумы температурного поля.

Обзор литературы. Современные методы анализа температурных полей в жаропрочных материалах включают использование вычислительной гидро- и газодинамики (CFD) и экспериментальных подходов. CFD позволяет моделировать температурное распределение с учётом сложных геометрических форм и условий эксплуатации, но требует значительных вычислительных мощностей и точных исходных данных. Экспериментальные методы, такие как термография и использование тепловых датчиков, дают высокую точность, но сталкиваются с трудностями в экстремальных условиях и с высокой стоимостью оборудования. В последние годы наблюдается активное развитие применения нейронных сетей для моделирования физических процессов. Эти сети эффективно используются для прогнозирования температурных распределений, оценки тепловых потоков и других задач, связанных с анализом сложных нелинейных систем. Ключевые преимущества нейронных сетей: способность обучаться на больших объёмах данных, их адаптивность и возможность работы с неполной или неоднородной информацией.

Основные ограничения традиционных методов, таких как CFD и аналитические подходы, заключаются в их высокой вычислительной сложности, необходимости точного определения физических параметров и ограниченной возможности применения в реальном времени. В отличие от них машинное обучение значительно ускоряет процесс анализа данных. В результате нейронные сети можно рассматривать как один из инструментов при решении теплообменных задач.

Постановка задачи. Модель температурного поля турбинной лопатки строится на основе анализа теплообмена при экстремальных температурах. Лопатка изготавливается из жаропрочного сплава, который отличается высокой термостойкостью и прочностью. Формирование температурного поля происходит из-за теплового излучения горячих газов, конвективного теплообмена с окружающей средой и теплопереноса внутри материала. На модель также оказывают влияние такие параметры, как сложная форма лопатки, неравномерность распределения тепловых потоков и особенности эксплуатационных условий. Задача математически формализуется как поиск точки максимума температурного поля $T(x,y,z)$ на наружной поверхности лопатки, омываемой высокотемпературной газовой средой. Данное температурное поле удовлетворяет уравнению нелинейной теплопроводности для стационарного процесса без внутренних источников теплоты

$$\operatorname{div}(\lambda \operatorname{grad} T) = 0$$

и граничному условию на поверхности теплоподвода

$$\alpha(T_g - T) = \lambda \operatorname{grad} T,$$

где T – температура на поверхности лопатки; λ – коэффициент теплопроводности материала лопатки; α – коэффициент теплоотдачи на поверхности лопатки; T_g – температура нагревающей газовой среды.

Задача поиска максимума сводится к нахождению таких координат (x^*, y^*, z^*) , для которых выполняется условие

$$T(x^*, y^*, z^*) = \max_{(x,y,z) \in S} T(x, y, z),$$

где S – поверхность лопатки.

Данные для анализа включают характеристики материалов, параметры геометрии и внешние воздействия. Используемая информация включает следующие элементы:

- материалы: жаропрочные сплавы, такие как никелевые сплавы, с заранее известными тепловыми свойствами (теплопроводность, удельная теплоёмкость);
- геометрия: трёхмерная модель лопатки, учитывающая все элементы, включая охлаждающие отверстия;
- нагрузки: температура, скорость течения рабочей среды, а также тепловое излучение от продуктов сгорания;
- граничные условия: температура на основании лопатки, параметры охлаждающего воздуха и коэффициенты теплоотдачи для различных участков её поверхности.

Эти данные являются основой для создания и обучения нейронной сети, которая будет прогнозировать точку максимальной температуры на поверхности лопатки с учётом всех факторов эксплуатации.

Методы. Архитектура нейронной сети, используемой для решения задачи нахождения точки максимума температурного поля, основывается на методах, предназначенных для работы с пространственными данными. Для этой задачи была выбрана свёрточная нейронная сеть (CNN), адаптированная для обработки трёхмерных данных. Сеть включает несколько свёрточных и пуллинг-слоев, которые извлекают пространственные и температурные особенности поля, а также полносвязные слои для выполнения классификации или регрессии с целью предсказания координат максимума температуры. Для улучшения фокусировки сети могут быть использованы механизмы внимания, позволяющие выделять ключевые области температурного поля.

Данные предварительно преобразуются с использованием метода конечных элементов (FEM), который моделирует температурные поля. На вход сети поступают трёхмерные тензоры, представляющие температурные значения на узлах сетки. Эти данные нормализуются для устранения различий в масштабе, а для улучшения качества обучения применяются техники аугментации, такие как случайное вращение, изменение масштаба и добавление шума. Кроме того, набор данных дополняется информацией о граничных условиях и физических характеристиках, которые кодируются как дополнительные признаки. Алгоритмы обучения включают такие компоненты, как функция потерь, регуляризация, оптимизация.

Функция потерь. Для задачи регрессии, направленной на предсказание координат точки максимума, используется функция потерь на основе среднеквадратичной ошибки (Mean Squared Error, MSE):

$$L = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|^2,$$

где y_i – истинные координаты точки максимума; \hat{y}_i – предсказанные координаты.

Регуляризация. Для предотвращения переобучения используются методы дропаут и нормализации весов. Дополнительно применяется метод ранней остановки, который завершает обучение, когда функция потерь на валидационной выборке стабилизируется.

Оптимизация. Для обновления весов сети применяется алгоритм Adam, который обеспечивает быстрый и стабильный процесс обучения. Начальные параметры, такие как скорость обучения, регулируются с помощью scheduler-методов, которые постепенно уменьшают её значение по мере стабилизации функции потерь.

Применение вышеуказанных методов позволяет эффективно обучить нейронную сеть, способную предсказывать точку максимума температурного поля даже в условиях сложных геометрий и неоднородных тепловых нагрузок.

Результаты экспериментов. Для проверки эффективности предложенного подхода была проведена серия экспериментов, направленных на оценку точности, скорости и устойчивости нейронной сети в задачах определения точки максимума температурного поля на поверхности турбинной лопатки.

Генерация и обработка обучающих данных. Для формирования обучающей выборки использовался метод конечных элементов (FEM) с применением программного обеспечения, специализированного на тепловом анализе сложных конструкций. Геометрия лопатки создавалась в виде трёхмерной модели с детализацией охлаждающих каналов и учётом физических параметров жаропрочного сплава.

Расчёт температурных полей проводился для различных эксплуатационных сценариев:

- температура рабочей среды варьировалась в диапазоне 900...1400 К;
- граничные условия включали конвективный теплообмен с внешней средой и охлаждающим потоком внутри каналов;
- учитывались тепловые нагрузки.

В результате моделирования было сгенерировано 10 000 температурных полей, представленных в виде трёхмерных массивов, содержащих значения температуры в узлах сетки конечных элементов. Для каждого температурного поля координаты точки максимума ($x_{\max}, y_{\max}, z_{\max}$) извлекались как целевая метка. Массивы данных нормализовались по максимальному значению температуры, а точки были представлены в единицах длины.

Для проверки обобщающей способности сети обучающая выборка включала 80 % данных, а 20 % выделялись на тестирование.

Оценка точности модели на тестовой выборке. Точность модели оценивалась по нескольким метрикам:

- Среднеквадратичная ошибка (Mean Squared Error, MSE) для координат точки максимума:

$$MSE = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|^2,$$

где y_i – истинные координаты точки максимума; \hat{y}_i – предсказанные координаты.

Для тестовой выборки значение MSE составило 0,05 мм², что свидетельствует о высоком уровне точности.

- Средняя абсолютная ошибка (Mean Absolute Error, MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|$$

составила 0,18 мм, что приемлемо для инженерных приложений.

- Средняя ошибка в предсказании температуры в точке максимума составила менее 1,5 %.

Кроме того, был проведён визуальный анализ распределений температуры для предсказанных и истинных точек. Результаты показали хорошее совпадение в зонах перегрева и основных особенностях температурных полей.

Сравнение с традиционными методами. Для оценки эффективности предложенного подхода было протестировано два классических метода:

1. **Аналитические методы.** Упрощённые модели, основанные на решении уравнения теплопроводности для простых геометрий, показали низкую точность. В сложных эксплуатационных условиях ошибка в определении точки максимума достигала 10...15 %.

2. **Метод конечных элементов.** FEM обеспечивал высокую точность (менее 1 %), однако был крайне ресурсоёмким. Расчёт одного поля на специализированной рабочей станции занимал 10...15 мин.

Предложенный метод на основе нейронных сетей показал следующие преимущества:

- **Скорость.** Время предсказания температурного поля с нахождением точки максимума составило менее 0,01 с, что делает метод подходящим для задач в реальном времени.

- **Точность.** Средняя ошибка сравнима с результатами FEM, при этом обеспечивается значительно более высокая производительность.

Устойчивость и обобщающая способность модели. Для проверки устойчивости модели были проведены тесты с использованием данных, отличных от обучающей выборки:

- изменение геометрии охлаждающих каналов;
- добавление шума в исходные данные;
- варьирование тепловых характеристик материала.

Модель продемонстрировала стабильные результаты предсказаний, сохраняя среднюю абсолютную ошибку (MAE) на уровне 0,2 мм, что подтверждает её способность эффективно обобщать и адаптироваться к новым условиям.

Заключение. Результаты экспериментов подтверждают, что предложенный подход на основе нейронной сети позволяет значительно ускорить процесс анализа температурных полей без потери точности. Это открывает новые возможности для применения машинного обучения в задачах теплового анализа и оптимизации конструкций лопаток газотурбинного двигателя.

Представленная нейронная сеть показывает высокую точность в определении точки максимума температурного поля на поверхности турбинной лопатки. Однако в процессе анализа ошибок было выявлено, что в зонах со сложной геометрией или при резких изменениях температурных градиентов модель может либо завышать, либо занижать значения температуры. Для решения данной проблемы требуется разработка гибридных методов, которые сочетают нейронные сети с традиционными физическими моделями для обеспечения высокой точности и надёжности.

Результаты исследования позволят на практике достаточно быстро определять наиболее термонагруженные участки оболочки лопатки газотурбинного двигателя, что в свою очередь позволит оптимизировать работу системы внутреннего охлаждения турбинных лопаток за счёт интенсификации охлаждения в наиболее нагруженных областях.

ЛИТЕРАТУРА

1. Andrianov, I. K. Optimizing Crack Detection in Gas Turbine Blades Using Implanted Capsules of Ionizing Gas in Nonsteady Operation at Nonuniform Temperature / I. K. Andrianov, E. K. Chepurnova // Russian Engineering Research. – 2023. – Vol. 43, No. 11. – P. 1361-1366. – DOI 10.3103/s1068798x23110035.
2. Андрианов, И. К. Оценка предельного давления и геометрии капсул в системе обнаружения трещин лопаток газотурбинного двигателя в условиях нестационарности и температурной неравномерности / И. К. Андрианов, Е. К. Чепурнова // Вестник машиностроения. – 2023. – Т. 102. – № 9. – С. 725-730.
3. Andrianov, I. K. Optimal distribution of capsules with active substance for the crack detection system in a turbine blade body / I. K. Andrianov, E. K. Chepurnova // CIS Iron and Steel Review. – 2023. – Vol. 26. – P. 98-104. – DOI 10.17580/cisr.2023.02.16.
4. Bejan A. (2013). Convection Heat Transfer. Wiley.
5. Kline M. Kay, R. (2020). «Deep Learning Applications in Engineering: A Survey». Engineering Computations, 37(4), 1205-1234.
6. Goodfellow I., Bengio Y., Courville A. (2016). Deep Learning. MIT Press.
7. Patankar S. V. (1980). Numerical Heat Transfer and Fluid Flow. Hemisphere Publishing Corporation.
8. Smith R. J., Brown D. L. (2018). «Neural Networks for Predicting Material Properties in High-Temperature Environments». Journal of Computational Physics, 356, 124-137.
9. Kingma D. P., Ba J., (2014). «Adam: A Method for Stochastic Optimization».
10. Rumelhart D. E., Hinton G. E., Williams R. J. (1986). «Learning Representations by Back-Propagating Errors». Nature, 323, 533-536.
11. Zhou J., et al. (2021). «Physics-informed Machine Learning for Thermal Field Prediction in Aerospace Applications». Applied Thermal Engineering, 183, 116149.
12. Chakraborty S., Goswami S. (2019). «Finite Element Modeling and Neural Networks for Structural Health Monitoring». Structural Control and Health Monitoring, 26(8), e2384.
13. He K., Zhang X., Ren S., Sun J., (2015). «Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification».