

ПАРОТУРБИННЫЕ, ГАЗОТУРБИННЫЕ,
ПАРОГАЗОВЫЕ УСТАНОВКИ
И ИХ ВСПОМОГАТЕЛЬНОЕ ОБОРУДОВАНИЕ

ОПРЕДЕЛЕНИЕ ПРОФИЛЬНЫХ ПОТЕРЬ
КИНЕТИЧЕСКОЙ ЭНЕРГИИ ПОТОКА В ТУРБИННЫХ РЕШЕТКАХ
С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ¹

© 2025 г. В. А. Тищенко^{a, b}, А. А. Белоусова^c, П. М. Нестеров^{a, *}, А. О. Смирнов^{b, **}

^aНациональный исследовательский университет “Московский энергетический институт”,
Красноказарменная ул., д. 14, Москва, 111250 Россия

^bАкционерное общество “Силовые машины – ЗТЛ, ЛМЗ, Электросила, Энергомашэкспорт”,
ул. Ватутина, д. 3, лит. А, Санкт-Петербург, 195009 Россия

^cАкционерное общество “Атомэнергопроект”, Бакунинская ул., д. 7, стр. 1, Москва, 107996 Россия

*e-mail: NesterovPM@mpei.ru

**e-mail: SmirnovAOI@mpei.ru

Поступила в редакцию 27.12.2023 г.

После доработки 27.11.2024 г.

Принята к публикации 04.12.2024 г.

Рассмотрены вопросы применения нейронных сетей для прогнозирования газодинамических характеристик решеток турбомашин. Представлены результаты разработки архитектуры моделей глубокого машинного обучения для определения профильных потерь кинетической энергии за плоскими сопловыми и рабочими (активного типа) турбинными решетками. Описана процедура подготовки обучающего датасета с использованием численного моделирования вязких потоков. Выполнен анализ сгенерированного набора данных, выделены его недостатки, которые необходимо устранить для повышения качества обучаемых нейронных сетей. Проведена работа по подбору архитектуры нейронных сетей для рабочих и сопловых решеток. Исследования показали, что одинаковая структура моделей эффективна как для сопловых, так и для рабочих решеток. Применение подготовленных моделей обеспечило хорошее совпадение результатов расчета с имеющимися данными для рассмотренных решеток всех типов. При этом отмечено некорректное предсказание нейронных сетей в трансзвуковых и сверхзвуковых режимах вблизи теоретического числа Маха за решеткой, равного 1. Это связано с отсутствием информации о подобных режимах в обучающем наборе данных. Дополнительное обучение моделей в сверхзвуковых режимах позволило обеспечить “отслеживание” влияния волновой структуры потока на энергетические характеристики за решеткой. На основе полученных данных выделены важность представления криволинейных межлопаточных каналов в параметрическом виде и необходимость подготовки обучающих данных в широком диапазоне изменения большинства независимых параметров. Нейронные сети показали высокую эффективность при решении поставленной задачи, что позволило сформулировать ряд концепций алгоритмов их применения при решении задач проектирования турбинных ступеней.

Ключевые слова: нейронные сети, газодинамика решеток турбомашин, профильные потери энергии, численное моделирование, турбинные ступени, теоретическое число Маха

DOI: 10.56304/S0040363623601677

Совершенствование турбомашин – комплексный процесс оптимизации конструкций их узлов и компонентов. Одним из наиболее важных направлений повышения аэродинамической эффективности проточной части как паровых, так и газовых энергетических турбин является организация течения рабочего тела в ступенях при минимальных потерях, которая представляет собой многокритериальную проблему. Для ее решения

требуется учет множества факторов: характера распределения теплоперепадов, углов выхода потока из решеток в номинальном режиме работы, степени реактивности и т.д., влияющих на форму лопаточных аппаратов, из которых формируются рабочие и сопловые решетки многоступенчатой турбины. Главными критериями, определяющими направление поиска оптимального варианта, являются минимизация потерь энергии и обеспечение требований к прочностным характеристикам элементов проточных частей.

¹ Работа выполнена при финансовой поддержке Российского научного фонда (грант № 23-19-00445 от 15.05.2023).

В настоящее время разработка проточной части представляет собой итерационный процесс, в котором учитываются имеющиеся у производителя турбинного оборудования наработки [1, 2]. На первом этапе проводятся предварительные одномерные или осесимметричные вариационные расчеты с опциональной возможностью использования различных оптимизационных методик, например [3], определяющих общий облик проточной части и основные характеристики каждой ступени. На этом этапе, когда отсутствует подробная информация о конструкции лопаточных аппаратов, аэродинамическая эффективность оценивается с помощью методов, базирующихся на регрессионном анализе уже имеющихся данных о профилях. С помощью этих методов [4, 5] обобщается информация об эффективности лопаток и предлагаются аналитические и эмпирические выражения (либо табличные данные), позволяющие оценить потери в решетках с использованием результатов предварительного расчета.

На основе выбранного оптимального варианта компоновки проточной части проводится профилирование лопаток и формируется представление геометрических характеристик с учетом особенностей пространственного течения в различных зонах решетки [6], критериев прочности (растяжение, изгиб, вибрационная надежность и др.) и других особенностей (например, выдува охлаждающего воздуха на поверхности лопаток). После этого производится трехмерный CFD-расчет с использованием верифицированных численных методов моделирования, например уравнений Навье – Стокса (как правило, в осредненной по Рейнольдсу постановке), с учетом вязкости рабочего тела. С помощью подробного численного моделирования газодинамики можно определить аэродинамическую эффективность решеток и проточной части в целом, принимая во внимание сложный трехмерный характер течения и особенности разработанной конструкции решеток.

Как правило, итоговый вариант может быть получен в результате нескольких итераций, когда после проведения численного моделирования происходит корректировка геометрических характеристик лопаток либо возврат к предварительному расчету с целью найти более оптимальное распределение параметров по ступеням. Количество циклов и эффективность методик на каждом этапе определяют время и ресурсы, затрачиваемые на выработку необходимого решения.

Несмотря на то что такую технологию успешно используют производители турбинного оборудования на протяжении многих лет, она не лишена некоторых недостатков, ограничивающих ее возможности [7].

Регрессионные методы оценки аэродинамической эффективности, применяемые на первом

этапе, обладают довольно низкой точностью [1]. Это приводит к тому, что полученный набор параметров проточной части имеет широкий диапазон неопределенности, в котором находится реальное оптимальное решение. Как показали данные [8], высокой точности регрессионных методов удается добиться при формировании эмпирических зависимостей для каждого профиля отдельно, что не является эффективным. Кроме того, с помощью этих методов невозможно определить геометрические характеристики лопаток для профилей, информация о которых не использовалась при их разработке. Внедрение в методики новых данных, полученных в результате численного моделирования или натурных испытаний, представляет собой довольно серьезную проблему, так как может вызвать изменение характера эмпирических выражений и снижение их точности в области ранее отработанных параметров. Таким образом, реализация новых конструкторских решений может привести к увеличению времени, затрачиваемого на проектирование. Кроме того, регрессионные методы не очень подходят для исследования работы турбомашин в переменных режимах.

В отличие от регрессионных, CFD-методы не ограничены диапазоном геометрических характеристик лопаток, их применение существенно дешевле и быстрее натуральных и экспериментальных испытаний. Однако они также имеют ряд недостатков. Помимо фундаментальных проблем [9], существует негативный фактор, связанный со спецификой их применения в турбомашиностроении. Они используются, как правило, для моделирования не отдельной ступени, а их групп, отсеков цилиндра. Это является ресурсоемкой задачей, для решения которой необходимы построение сложной расчетной сетки с учетом всех требований к точности расчета, длительное время моделирования и повышение расчетной производительности кластеров. Кроме того, эта технология сильно зависит от опыта и квалификации инженера-расчетчика. Таким образом, процесс доведения конструкции лопаточных аппаратов до оптимального состояния с учетом итераций может занять довольно много времени. На этапе между профилированием и проведением численного моделирования необходимо внедрение промежуточной процедуры, с помощью которой можно достаточно точно и, что немаловажно, быстро оценить возможность достижения требуемых показателей эффективности без применения сложных вычислений.

Для дальнейшего совершенствования аэродинамических характеристик проточных частей турбин с учетом развития современных паротурбинных и газотурбинных технологий необходимо расширение области поиска таких конструкторских решений, которые ранее не применялись.

Использование традиционных приемов проектирования, в силу описанных ранее проблем, может привести к излишним ресурсным и временным затратам для решения этих задач. Системе проектирования не хватает возможности саморасширения с учетом новых требований к параметрам разрабатываемых узлов и увеличения списка факторов, влияющих на итоговый результат [10].

Решением данной проблемы может стать внедрение в процесс проектирования методов, основанных на глубоком машинном обучении, — нейронных сетей, которые способны создавать сложные нелинейные связи между признаками (входными данными) и целевыми показателями, на значение которых эти параметры влияют. По сравнению с регрессионными методами, нейронные сети обладают значительно большими обобщающими способностями. В настоящее время многие производители турбинного оборудования ведут работы по внедрению моделей, использующих нейронные сети, в процессы проектирования. Так, например, General Electric планирует с их помощью снизить время разработки новых проектов на 30–50% [11], а в Baker Hughes уже отметили двукратный прирост скорости разработки узла поршневого компрессора с применением нейронных сетей [12]. Подобные модели способны решать широкий спектр задач и могут быть интегрированы в процесс на всех этапах проектирования турбомашин. Рассмотрены их возможности при профилировании лопаточных аппаратов [13, 14], оценке распределения газодинамических параметров потока по образующим межлопаточных каналов [15, 16] и повышении скорости и точности выполнения CFD-расчетов [7].

Одной из их особенностей является этап обучения нейронных сетей — определение весовых коэффициентов нейронов модели по набору данных (датасета), в котором входным параметрам (признакам) задано соответствие известному значению искомого целевого параметра (или параметров) [17]. Ввиду сложности структуры и большого количества свободных параметров, настройка которых необходима в процессе обучения, для нейронных сетей требуется значительно больший объем специально подготовленных данных по сравнению с традиционными статистическими методами. Это — одна из основных проблем внедрения новых подходов к устоявшимся процессам, так как нужно структурировать и обработать большой объем информации, которая накапливалась годами и даже десятилетиями.

В настоящей работе исследуется вопрос практического применения нейронных сетей для определения профильных потерь энергии в решетках турбомашин. Выполнена процедура разработки двух нейронных сетей, которые могут ис-

пользоваться для прогнозирования профильных потерь кинетической энергии в сопловых и активных рабочих турбинных решетках. Описываются все основные этапы подготовки и применения моделей: формирование обучающего датасета, разработка архитектуры и обучение нейронной сети, применение модели и сравнение результатов ее работы с эталонными показателями. Такой способ оценки профильных потерь энергии может быть использован, например, вместо методов оценки потерь энергии на первом этапе проектирования проточной части. В работе рассматривается способность нейронной сети адаптироваться — возможность дообучения модели с помощью новых данных, расширяющих диапазон режимов с проявлением новых физических явлений, без изменения архитектуры самой модели. На основе полученных данных анализируется возможность применения нейронных сетей для решения задач в области аэродинамики турбомашин и обсуждается ряд концепций их интеграции в процедуры разработки лопаточных аппаратов турбомашин.

ПОДГОТОВКА ОБУЧАЮЩЕГО ДАТАСЕТА

Для расчета профильных потерь кинетической энергии были выбраны шесть профилей лопаток (рис. 1). Данные по строению и оптимальным параметрам решеток заимствованы из [5].

Для определения целевого параметра (профильных потерь кинетической энергии за решеткой) была проведена серия численных расчетов с применением CFD-кода ANSYS Fluent. В данном случае исходные данные для обучения нейронных сетей генерируются посредством моделирования, однако, безусловно, они также могут быть сформированы на базе результатов натурных или лабораторных испытаний. Моделирование проводили в двумерной постановке. Для этих целей создавали расчетную сетку, главные параметры которой для каждого из вариантов поддерживались на постоянном уровне с целью обеспечить корректность сравнения газодинамических характеристик.

На рис. 2, а представлена расчетная сетка одного из вариантов решетки. Вблизи поверхностей межлопаточного канала генерируемые ячейки формировались таким образом, чтобы в пристеночной области безразмерная координата центра первой ячейки составляла $y^+ \approx 1$, что позволяет подробно рассчитать параметры пограничного слоя, “захватывая” в процессе моделирования вязкий ламинарный подслой. На каждую расчетную область решетки приходится примерно 25000 ячеек, что соответствует зоне нечувствительности для каждого профиля. Дальнейшее увеличение количества ячеек не приводит к изменению результатов расчетов. Для моделирования эффектов вязкости при течении рабочего тела в




Рис. 1. Исследуемые профили лопаток. *a* – С-9012А; *б* – С-9015А; *в* – С-9018А; *г* – Р-2617А; *д* – Р-3021А; *е* – Р-3525А




Рис. 2. Расчетная схема турбинной решетки С-9012А в двумерной постановке профиля (*a*) и изолинии чисел Маха в решетке из профилей С-9012А (*б*)

решетках использовали модель турбулентности $k-\omega$ SST. Термодинамические характеристики рабочего тела, движущегося в решетке, соответствуют характеристикам воздуха, параметры которого подчиняются уравнению состояния Менделеева – Клапейрона.

Основная цель расчетов – формирование набора данных для обучения моделей нейронных сетей. Помимо варьирования строения самих профилей проводили численное моделирование различных режимов течения рабочего тела через решетку, а также геометрических характеристик самих решеток. Для каждого профиля лопатки рассматривали течение при трех значениях шага решетки, трех углах установки лопатки и девяти значениях теоретического числа Маха за решеткой (на дозвуковых режимах). Таким образом, на каждый профиль лопатки приходится более 40 различных вариантов расчетов.

Граничные условия перед решетками при моделировании оставались постоянными: давление полного торможения воздуха $p_0 = 116.3$ кПа, температура полного торможения $T_0 = 303$ К. Стати-

ческое давление за решеткой p_1 вычисляли по формуле

$$p_1 = \frac{p_0}{\left(1 + \frac{k-1}{2} M_{lr}^2\right)^{\frac{k}{k-1}}}, \quad (1)$$

где k – показатель изоэнтропы воздуха, равный 1.4; M_{lr} – теоретическое число Маха за решеткой.

На рис. 2, б представлен пример результатов расчета – изолинии чисел Маха в межлопаточном канале и за ним. Целевой показатель профильных потерь кинетической энергии потока ζ определяли осреднением его значений вдоль шага на расстоянии $0.2 b$ (20%) от хорды решетки. В каждой точке изолинии значение этой характеристики рассчитывали по выражению [18]

$$\zeta = \frac{2}{(k-1)M_{lr}^2} \left[\left(\frac{p_0}{p_{01}} \right)^{\frac{k-1}{k}} - 1 \right], \quad (2)$$

где p_{01} – давление полного торможения потока в рассматриваемой точке за решеткой.

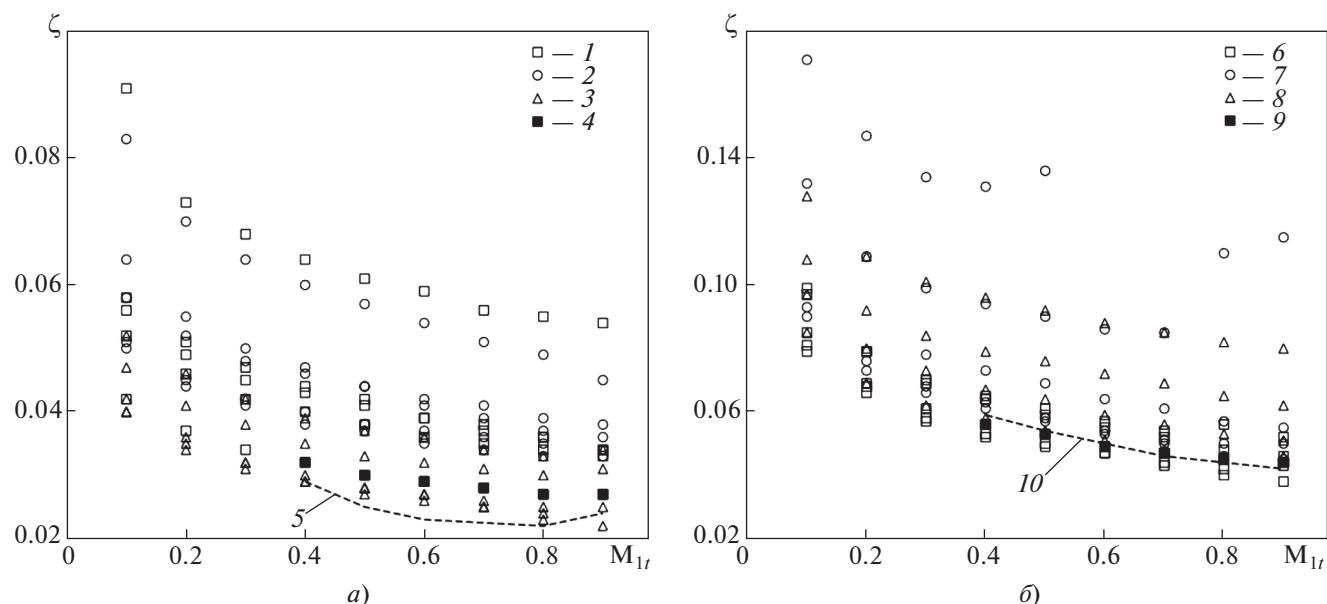


Рис. 3. Зависимость профильных потерь кинетической энергии ζ от теоретического числа Маха за сопловыми (а) и рабочими (б) решетками при CFD-моделировании (1–4, 6–9) и экспериментальные данные (5, 10). а: 1 – С-9012А; 2 – С-9015А; 3 – С-9018А; 4 – С-9012А соответствуют экспериментальным данным 5; б: 6 – Р-2617А; 7 – Р-3021А; 8 – Р-3525А; 9 – Р-2617А соответствуют экспериментальным данным 10

Далее представлена информация о параметрах, которые напрямую или косвенно изменялись и рассматривались в виде входных признаков формируемого датасета для нейронных сетей.

Для сопловой решетки:

теоретическое число Маха за решеткой M_{1t} , угол установки профиля α_y , шаг решетки t – параметры изменялись при проведении расчетов;

радиус входной r_1 и выходной r_2 кромок, хорда профиля b , эффективный угол выхода α_1 – параметры использовались для описания формы профиля, определялись значениями из [1] для каждого сечения, не изменялись при варьировании режима обтекания.

Для рабочей решетки:

теоретическое число Маха за решеткой M_{1t} , угол установки профиля β_y , шаг решетки t – параметры изменялись напрямую при проведении расчетов;

радиус входной кромки r_1 – параметр использовался для описания формы профиля, определялся значениями из [1], изменялся при варьировании рассчитываемого объекта исследования.

Важно подчеркнуть, что параметры α_1 , β_1 , β_2 (здесь β_1 , β_2 – углы входа потока в рабочую решетку и выхода из нее) не являются характеристиками потока, от них зависят профиль решеток и формируемый ими межлопаточный канал.

На рис. 3 в виде облака точек представлены результаты численного моделирования, из которых

составлен обучающий датасет для нейронных сетей. На рисунке для одной сопловой и одной рабочей решеток в виде линий отмечены данные экспериментальных испытаний из [5], а закрашенными маркерами – соответствующие им точки CFD-моделирования. Как следует из рисунка, расчетные данные удовлетворительно соответствуют линиям экспериментов, а их рассогласование может быть связано с погрешностью численного моделирования, способом и областью определения потерь, погрешностью экспериментальных измерений. При этом характер поведения рассчитанной зависимости потерь от теоретического числа Маха является корректным с точки зрения физических процессов, протекающих в расширяющемся потоке – увеличение числа Маха приводит к снижению целевого показателя [19]. В рабочих решетках активного типа профильные потери энергии больше, чем в сопловых решетках, а их разброс значительно шире, что связано с чувствительностью профилей этого типа к отклонению строения решеток от оптимального.

Таким образом, подготовлен обучающий датасет для сопловых и рабочих решеток, в котором однозначно соотносятся геометрические характеристики решеток и режима течения в них с целевым признаком – профильными потерями кинетической энергии (коэффициентом профильных потерь энергии) ζ , при этом степень влияния на него каждого входного признака различна.

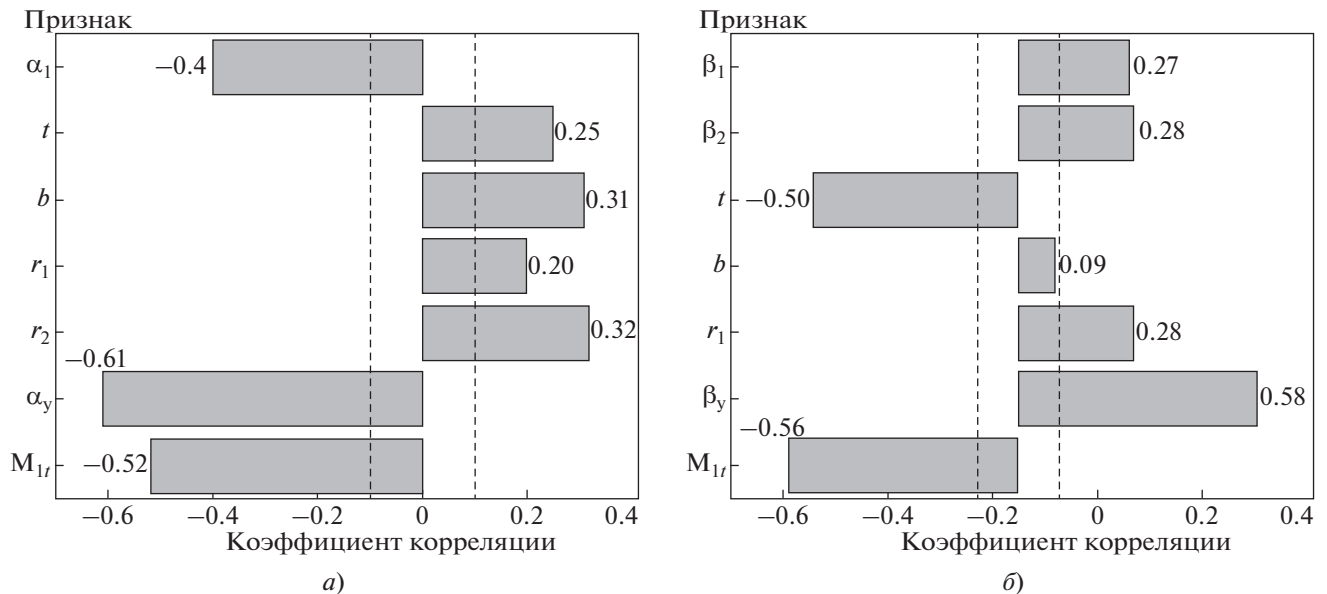


Рис. 4. Коэффициент корреляции между профильными потерями кинетической энергии и входными признаками формируемого датасета для сопловых (а) и рабочих (б) решеток

На рис. 4 представлены данные, характеризующие статистическую степень “влияния” входного признака на значение коэффициента профильных потерь энергии в решетке — чем выше по модулю коэффициент корреляции, тем сильнее связаны между собой рассматриваемые характеристики, а его знак определяет прямую или обратную пропорциональность между ними. Вертикальными линиями ограничена область значений коэффициента корреляции (от -0.1 до 0.1), внутри которой можно говорить об отсутствии связи между признаком и целевым параметром. Как следует из представленных данных, все параметры имеют статистическое влияние на потери энергии, за исключением хорды рабочих лопаток, что обусловлено слабым изменением этого параметра у выбранных решеток. На основе анализа подобного представления взаимосвязей и сопоставления их с физической картиной механизмов влияния того или иного параметра можно судить о качестве и полноте сформированного датасета.

Некоторые параметры имеют однозначную связь с потерями в сопловых решетках. Например, снижение потерь с ростом угла выхода потока из сопловой решетки α_1 связано с уменьшением угла поворота в межлопаточном канале (так как угол входа остается постоянным и составляет 90° для всех рассмотренных сопловых лопаток) и, как следствие, с ростом степени конфузности, приводящим к уменьшению толщины потери импульса вблизи выходной кромки лопатки [21]. Рост потерь вызван увеличением радиусов входных r_1 и выходных r_2 кромок, хорды b при обратно пропорциональной связи с теоретическим чис-

лом Маха M_{1r} в дозвуковом диапазоне режимов. Влияние на профильные потери шага решетки и угла установки более сложно, так как при фиксации одного из этих параметров второй будет иметь значение оптимума, при котором достигаются минимальные потери энергии, и его последующее изменение в большую или меньшую сторону будет приводить к росту целевого показателя. Каждый из этих параметров в первую очередь определяет (если рассматривать только механизм их влияния на профильные потери) условия течения на диффузорном участке спинки лопатки в косом срезе решетки [19], протяженность этой области и параметры потока в пограничном слое на входе в нее. На это также оказывают влияние локальная толщина профиля в горле и угол отгиба спинки лопатки [20, 21]. Таким образом, подготовленный датасет для сопловых решеток нельзя назвать полным — требуется дополнение входных признаков информацией о форме профиля. Эта идея будет раскрыта далее.

Для рабочих решеток наблюдается похожая картина недостатка информации о влиянии шага и угла установки, при этом знак влияния этих параметров меняется (см. рис. 4). Кроме того, для рабочих решеток следует обратить внимание на коэффициент корреляции для углов β_1, β_2 , которые в датасете изменяются одновременно при переходе от одного строения профиля к другому.

Эти особенности существенно снижают обобщающую способность подготовленных данных. Можно сказать, что обученные на них модели нейронных сетей будут ограничены при применении в широком спектре строения и режимов ра-

боты решеток – по-видимому, их обобщающие способности будут распространяться на решетки, включенные в этот датасет и на ближайшие из ряда форм профилей по характеристикам из [5]. Тем не менее, подготовленные данные позволяют отработать процессы обучения нейронных сетей, проверить качество их действия и диапазоны применимости.

РАЗРАБОТКА АРХИТЕКТУРЫ НЕЙРОННЫХ СЕТЕЙ И ИХ ОБУЧЕНИЕ

Разрабатываемые модели нейронных сетей должны сформировать такие связи между рассматриваемыми признаками и целевым показателем, чтобы они представляли зависимость, которую в общем виде можно записать для сопловых ζ_c и рабочих ζ_p решеток соответственно:

$$\zeta_c = f(M_{lr}, \alpha_y, t, r_2, r_1, b, \alpha_1); \quad (3)$$

$$\zeta_p = f(M_{lr}, \beta_y, t, r_1, b, \beta_1, \beta_2). \quad (4)$$

Каждая из нейронных сетей имеет семь нейронов во входном слое и один в выходном. Разработка архитектуры нейронных сетей для нового направления задач заключается в поиске оптимального количества скрытых слоев и их параметров, при которых функция потерь работы нейронной сети будет минимальной [17]. Выбор конфигурации модели и значений ее гиперпараметров проводили посредством байесовского алгоритма оптимизации [22], осуществляющего решение поставленной задачи с учетом вероятности присутствия минимума целевой функции в указанном диапазоне поиска. Для работы с нейронными сетями использовали библиотеку Tensorflow. Рассматривались варианты с различным количеством скрытых слоев (до 15) и нейронов внутри них (до 100), разным видом их функций активации и функции активации последнего слоя, наличием или отсутствием специализированных слоев регуляризации нейронной сети.

В качестве функции потерь, определяющей целевую функцию при обучении модели, изучали два варианта – среднюю абсолютную σ_{MAE} и среднеквадратическую σ_{MSE} ошибки, которые вычисляли по формулам

$$\sigma_{MAE} = \frac{1}{N} \sum_{i=1}^N |\zeta_i - \hat{\zeta}_i|; \quad (5)$$

$$\sigma_{MSE} = \frac{1}{N} \sum_{i=1}^N (\zeta_i - \hat{\zeta}_i)^2, \quad (6)$$

где ζ_i – значение целевого показателя, предсказанное моделью нейронной сети i -й точки обучающего датасета; $\hat{\zeta}_i$ – “правильное” значение целевого показателя i -й точки, взятое непосред-

ственно из обучающего датасета (результаты CFD-моделирования); N – количество точек для решеток данного типа (рабочей или сопловой).

Необходимо отметить, что минимизация погрешности в виде, представленном в формуле (5), слабее “штрафует” нейронную сеть за некорректное предсказание по сравнению с выражением (6). В настоящей работе авторы учитывают, что применяется ограниченный по объему обучающий датасет, а также что в исследовании используется неполный список параметров, характеризующих конструкцию решеток и режимы течения, которые к тому же, как было указано ранее, взаимосвязаны. Поэтому при использовании среднеквадратической ошибки нейронная сеть может оказаться переобученной (состояние, при котором нейронная сеть дает качественный результат при определении целевого показателя по значениям из обучающего датасета, но теряет обобщающую способность при применении ее на произвольных входных данных). Для контроля состояния переобучения датасет был разделен на тренировочный (на котором происходило обучение) и валидационный (на котором проверялась работоспособность нейронной сети) в пропорции 9 : 1 (90% на обучение, 10% на валидацию).

В таблице представлена архитектура нейронной сети, характеристики которой определены с помощью отмеченного ранее метода оптимизации и которая предсказывает профильные потери с минимальной погрешностью. Процесс ее обучения закончился при достижении 10000 итераций, скорости обучения (learning rate) 0.0001 и функции потерь. Данный вариант архитектуры оказался наилучшим из области поиска как для сопловых, так и для рабочих решеток. Разработанная модель оказалась довольно “глубокой” – она включает в себя 11 скрытых слоев с большим количеством нейронов. Помимо полносвязных слоев она также содержит один слой dropout (слой № 7), задача которого – в произвольном порядке отключать часть нейронов предыдущего слоя, тем самым предотвращая взаимoadaptацию нейронов на этапе обучения и снижая вероятность переобучения модели.

На рис. 5 показано изменение функции потерь в процессе обучения нейронных сетей подобранной архитектуры для сопловых и рабочих решеток. Имеется незначительное переобучение нейронной сети для сопловых решеток, которое в первую очередь связано с ограниченностью используемого набора данных. Тем не менее, рост рассогласования в тренировочных и валидационных результатах не наблюдается.

Таким образом, были обучены две нейронные сети с одинаковой архитектурой для определения профильных потерь в сопловых и рабочих решетках. Погрешность результатов их работы представ-

Архитектура нейронной сети

Номер слоя	Количество нейронов	Функция активации	Примечание
Полносвязный слой (Dense)			
1	7	Нет	Входной слой
2	14	relu	Скрытый слой
3	28	«	«
4	56	«	«
5	72	«	«
6	90	«	«
Исключение нейронов (Dropout)			
7	–	Нет	Скрытый слой
Полносвязный слой (Dense)			
8	72	relu	Скрытый слой
9	56	«	«
10	28	«	«
11	14	«	«
12	7	«	«
13	1	tanh	Выходной слой

лена на рис. 6. Как следует из рисунка, погрешность предсказания потерь $\Delta = \frac{\zeta_i - \hat{\zeta}_i}{\hat{\zeta}_i} \times 100\%$ для сопловых решеток лежит в диапазоне от -3 до 3% , а для рабочих решеток ширина разброса оказалась в 2 раза больше. При этом наблюдается склонность моделей завышать результат. Тем не менее, в абсолютных значениях подобная погрешность соответствует десятым долям процента, что позволяет сделать следующий вывод: представленные нейронные сети способны довольно точно определять потери энергии.

РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ РАЗРАБОТАННЫХ НЕЙРОННЫХ СЕТЕЙ

Разработанные модели проверяли путем сравнения их предсказаний с данными CFD-расчетов, не участвовавших в обучении и валидации. Результаты сравнения представлены на рис. 7, а, б для нейронных сетей профилей сопловых и рабочих решеток разных типов. Численное моделирование обозначено маркерами, а результаты работы моделей – линиями. Дополнительно были рассчитаны коэффициенты потерь для решеток С-9009А и Р-2314А, форму профилей которых не использовали при составлении обучающего да-




Рис. 5. Ошибки нейронной сети во время обучения для сопловых (а) и рабочих (б) решеток. 1 – обучающий датасет; 2 – валидационный датасет




Рис. 6. Погрешность предсказания потерь в сопловой (а) и рабочей (б) решетках в сравнении с данными CFD-расчетов. 1 – Δ ; 2 – σ_{MSE}

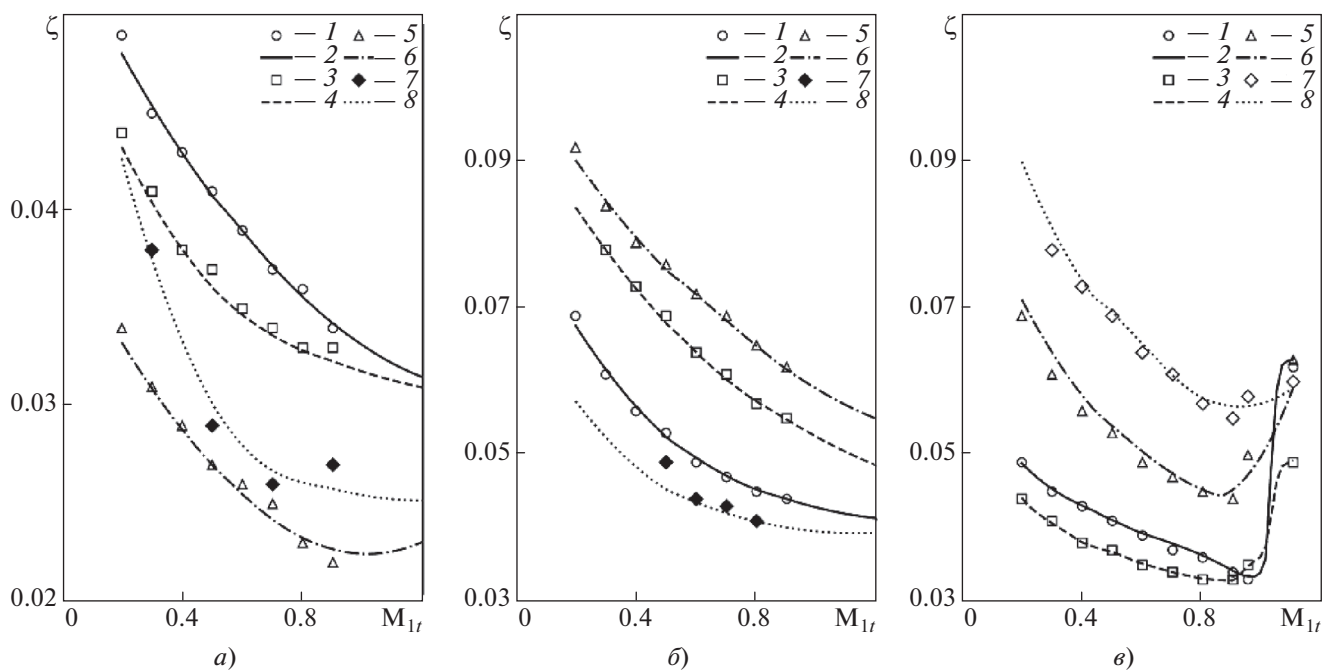


Рис. 7. Результаты применения обученных нейронных сетей для сопловых (а) и рабочих (б) решеток, а также дообученных моделей (в) при $M_{1r} > 0.9$.

1, 3, 5, 7 – CFD-расчет; 2, 4, 6, 8 – результаты работы моделей.
 а: 1, 2 – С-9012А; 3, 4 – С-9015А; 5, 6 – С-9018А; 7, 8 – С-9009А;
 б: 1, 2 – Р-2617А; 3, 4 – Р-3021А; 5, 6 – Р-3525А; 7, 8 – Р-2314А;
 в: 1, 2 – С-9012А; 3, 4 – С-9015А; 5, 6 – Р-2617А; 7, 8 – Р-3021А

тасета (на рисунках соответствуют закрашенным маркерам). Как следует из рисунков, разработанные модели хорошо прогнозируют значения коэффициентов потерь кинетической энергии для всех рассмотренных случаев. На основе ограниченных

данных удалось обобщить и сгенерировать скрытые связи между различными параметрами, которые обеспечивают хорошие предсказательные возможности для объектов, в явном виде не участвовавших в их формировании.




Рис. 8. Результаты оценки профильных потерь сопловых лопаток с помощью CFD-расчета (1, 3, 5) и модели нейронной сети (2, 4, 6).
1, 2 – С-9012А; 3, 4 – С-9015А; 5, 6 – С-9018А

При этом, как следует из данных на рис. 7, а, б, нейронные сети были применены и при $M_{1r} > 0.9$, для которого данные CFD-расчета отсутствуют. Их прогнозы в этой области теряют физическую корректность – наблюдается дальнейшее уменьшение профильных потерь с увеличением числа Маха. В реальности в подобных режимах должен наблюдаться кризис потерь первого рода [19] – появление локальных сверхзвуковых областей на спинке профиля, которые замыкаются волной сжатия, что приводит к росту потерь. В этих режимах возникают новые газодинамические процессы, способствующие формированию волновой структуры потока, которые не проявляются в подготовленных для обучения данных. Отсюда некорректное предсказание моделей в этой области режимов.

С целью проверить, имеется ли потенциал расширения уже созданных моделей, было дополнительно смоделировано течение потока для всех возможных вариантов признаков решеток при числах Маха 0.95, 1.05, 1.10. Эти CFD-расчеты использовались для дополнительного обучения и уточнения весовых коэффициентов нейронных сетей без изменения их архитектуры путем обучения только трех последних слоев на новом дополненном датасете. На рис. 7, в представлены результаты, полученные по доработанным моделям для некоторых решеток. Как видно, рассматриваемый подход хорошо адаптируется при появлении новой информации, что делает его гибким и удобным инструментом при проработке новых конструктивных реализаций. При этом подобное поведение доработанных моделей четко отражает критически важную особенность разработки и применения нейронных сетей – их предсказательные способности ограничиваются областями данных, в которых представлен соответствующий набор физических процессов.

Для сравнения на рис. 8 показаны результаты оценки профильных потерь сопловых лопаток с помощью методики, основанной на регрессионном подходе – зависимость от выбранных признаков описана степенным полиномом. Коэффициенты и значения степеней параметра при них определяли, как и в случае с нейронными сетями, исходя из минимума средней абсолютной ошибки (MAE). Как видно, данный метод значительно уступает разработанной модели нейронной сети. На рисунке отражается характерная проблема подобных методов [23] – они не способны предложить универсальный способ оценки искомого параметра без потери точности, расширяя область неопределенности. Среднеквадратическая погрешность составляет 6%, что в 6 раз больше погрешности рассматриваемой в статье нейронной модели.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ПРИ ИССЛЕДОВАНИИ АЭРОДИНАМИКИ РЕШЕТОК ТУРБОМАШИН

Проведенное в работе исследование показало, что нейронные сети могут стать эффективным инструментом для решения задач, связанных с аэродинамическими процессами в проточных частях турбомашин. Однако требуется более полное описание входных данных и соответствующего обучающего датасета. В рамках выполненного исследования он сильно ограничен как режимными параметрами (например, систематически не учтено влияние числа Рейнольдса), так и описанием формы профилей – используемый набор геометрических характеристик не способен в полной мере воспроизвести сложную криволинейную форму межлопаточных каналов. Этот негативный фактор удалось нивелировать исключительно благодаря близости и определенному подобию геометрических характеристик рассмотренных профилей лопаток.

Для улучшения предсказательных способностей нейронных сетей и повышения универсальности их применения важно построить информативно корректный обучающий датасет. Для этого необходимо расширить список варьируемых параметров, характеризующих режим работы решетки, а также обеспечить диапазон их изменения в рамках тех значений, которые будут впоследствии применяться нейронными сетями. Кроме того, решетка профилей в датасете должна быть определена набором параметров, значения которых однозначно описывают форму межлопаточного канала. При этом представление в виде координат точек не является эффективным, так как вносит значительное количество степеней свободы, что приведет к большим объемам формируемого обучающего датасета и сложности с обучением моделей. Наилучшим подходом будет




Рис. 9. Параметрическое представление профиля С-90-15А.

1 – точки профиля из [5]; 2 – образующие профиля, описанные кривыми Безье; 3 – узлы кривых Безье, формирующие опорные ломаные

применение параметризации геометрических характеристик лопаток – представления форм профиля и межлопаточного канала набором физически и геометрически интерпретируемых величин, комбинация которых однозначно определит облик сечения лопатки. Так, например, на основе доработанного подхода, приведенного в [24], плоские решетки профилей могут быть сформированы с помощью набора из 13 независимых параметров. Подобное представление, кроме того, может стать наиболее эффективным при генерации набора обучающих данных, так как процедура изменения формы профиля и последующего расчета можно автоматизировать.

На рис. 9 в качестве примера показан профиль С-90-15А, однозначно описанный набором из следующих параметров (в системе координат методики [24]): $\omega_1 = 55^\circ$, $\omega_2 = 60^\circ$, $\alpha_1 = 30^\circ$, $\alpha_2 = 66^\circ$, $x_{сл} = 0.2820$, $y_{сл} = 0.2120$, $r_1 = 0.0681$, $r_2 = 0.0082$, $r_{max} = 0.1161$, $x_{max} = 0.1436$ (здесь $x_{сл}$, $y_{сл}$, r_1 , r_2 , r_{max} , x_{max} – безразмерные величины). Форма профиля строится с помощью кривых Безье. На рисунке также приведены некоторые точки этого профиля [5]. Масштабировав строение в соответствии с хордой лопатки, а также задав шаг и угол установки, можно однозначно описать сечение турбинной решетки.

Методики на основе нейронных сетей могут быть применены для решения широкого спектра задач. Далее представлены некоторые концепции их использования (рис. 10). Поиск оптимальной формы пера лопатки при пространственном профилировании основан на классической методике профилирования лопаток большой верности [25]. Для этих целей используются четыре обученные нейронные сети (потенциально объединенные в одну) – для предсказания концевых 4 и профильных 5 потерь, коэффициента расхода 6, а также для распределения параметров потока по

высоте 2 (см. рис. 10, а). Лопатка представляется в виде набора плоских сечений, каждое из которых описывается параметрически 3. Входными данными являются параметры потока перед решеткой (распределение давления, теплоперепад на решетке, параметры работы турбомшины), закон закрутки, ограничения на возможные значения геометрических параметров профилей.

Для начальной формы лопатки рассчитывается распределение интегральных параметров решетки по высоте 1 (степень реактивности, коэффициенты скорости и расхода, удельные расходы), на основе которых нейронная сеть 2 определяет распределение предпочтительных углов входа и выхода и скоростей потока по высоте. Эти данные дискретно распределяются по выбранному набору сечений, информация по каждому из которых направляется в блок профилирования, в котором каждый профиль представляется в параметрическом виде 3, после чего определяются потери (только профильные или профильные и концевые) в нейронных сетях 4, 5, а также коэффициенты расхода 6. Далее полученные характеристики профиля направляются в блок 7, проводящий многомерную минимизацию – поиск наилучших геометрических характеристик профиля (путем варьирования) с учетом введенных ограничений и обеспечивающий наилучшие аэродинамические характеристики.

При необходимости оптимизатор выполняет несколько итераций минимизации целевой функции и цикл профилирования в блоке повторяется. При достижении оптимума по потерям и коэффициенту расхода информация о полученных геометрических характеристиках профилей по высоте возвращается обратно в блок расчета интегральных характеристик 1, в случае необходимости (при небалансе расходов или несоответствии заданным значениям коэффициентов рас-

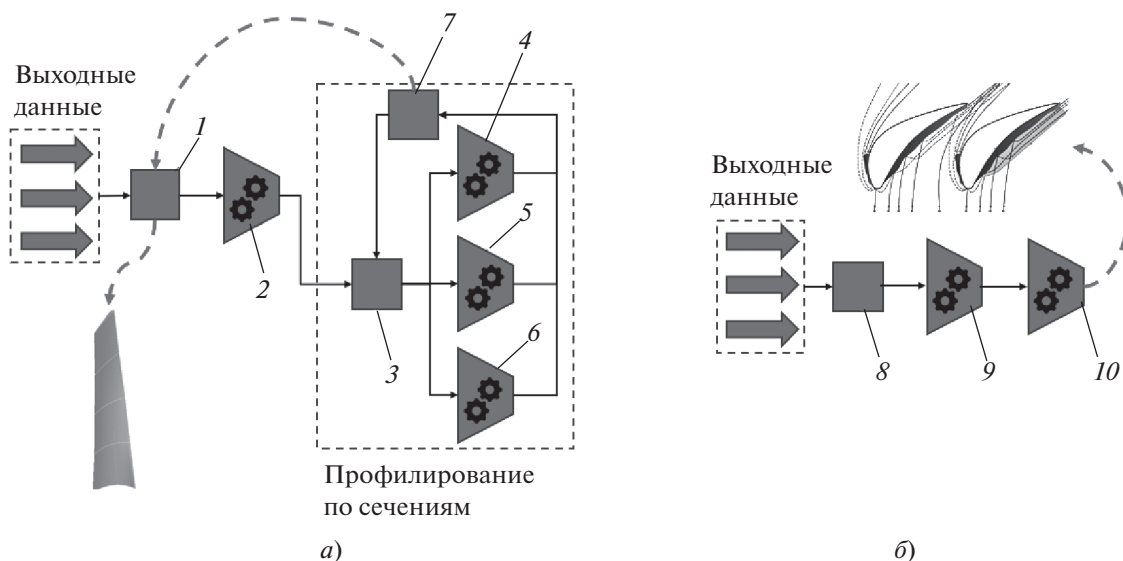


Рис. 10. Пространственное профилирование (а) и определение параметров жидкой фазы (б) при решении задач газодинамики лопаточных аппаратов турбомашин.

1 – определение параметров решетки по высоте; 2, 4, 5, 6, 9 – нейронная сеть определения параметров потока по высоте, профильных потерь, конечных потерь, коэффициентов расхода, параметров осаждения влаги на стенках межлопаточного канала; 3 – представление профиля в параметрическом виде; 7 – многомерная оптимизация; 8 – расчет распределения давления по обводу профиля; 10 – нейронная сеть предсказания параметров влаги за решеткой

хода или скорости) вся операция повторяется на базе уже уточненных данных. В противном случае на выходе формируется итоговая конструкция решетки с учетом пространственного профилирования. Похожий подход был отработан в [26] и показал существенное ускорение процесса проектирования лопаток.

Прогнозирование процессов осаждения влаги на поверхностях лопаток последней ступени цилиндра низкого давления конденсационных паровых турбин может стать крайне важным при решении задач проектирования ступеней, работающих в условиях влажно-паровых потоков. Сложность предсказания параметров возникновения, развития и движения влаги в проточных частях турбин обусловлена множеством факторов [27]: неравновесностью межфазных теплообменных процессов, наличием влаги в трех разных формах (пленка на поверхностях, мелкая влага, крупная влага), каждая из которых участвует в различных процессах, полидисперсным характером частиц дискретной фазы, движущихся в проточной части, и др. В итоге, довольно трудно на этапе проектирования точно оценить эффективность систем борьбы с эрозийным износом (внутриканальная сепарация пленок с поверхностей межлопаточных каналов), предсказать интенсивность развития эрозии на различных участках рабочих лопаток и т.д.

Однако в последнее время появляются модели описания поведения влаги в решетках турбо-

машин, построенные на результатах экспериментальных исследований [28]. С помощью этих моделей можно рассчитать основные характеристики крупной эрозионно-опасной влаги перед рабочими решетками (средний диаметр капель, скорость и направление их движения, их концентрацию), вдоль их шага, а также интенсивность осаждения капель на поверхностях лопаток, расход формирующейся пленки по обводам профиля и т.д. Основным недостатком таких моделей является длительное время, требуемое для проведения расчетов. Однако нейронные сети, обученные на результатах этих расчетов, могут существенно сократить время, затрачиваемое на определение интегральных характеристик жидкой фазы в решетках турбомашин.

Концепция алгоритма представлена на рис. 10, б. Входными данными являются геометрические характеристики профиля, давление перед решеткой, число Маха за ней, начальная влажность, дисперсный состав, представленный в виде параметров вероятностного распределения. Эта информация используется для проведения CFD-расчета 8 с целью установить, как распределяется статическое давление по обводу профиля. После этого входные данные и результаты моделирования направляются в нейронную сеть (или группу нейронных сетей, решающих отдельные задачи) 9, которая определяет характер распределения водяной пленки на поверхностях межлопаточного канала, а также интенсивность взаимодействия влаги с образующими профиля. На основе этих

данных вторая нейронная сеть *10* предсказывает основные параметры жидкой фазы перед следующей решеткой.

Таким образом, в результате действия подобного алгоритма будут доступны информация о распределении жидкой пленки на поверхностях профилей, что позволит разрабатывать более эффективные методы борьбы с влагой, а также основные кинематические характеристики крупной эрозионно-опасной влаги перед следующей решеткой (средние размеры капель, концентрация, векторы скоростей).

ВЫВОДЫ

1. Нейронные сети способны решать вопросы, связанные с газодинамикой решеток турбомашин в общем и потерями энергии в частности.

2. Важнейшую роль в вопросе подготовки моделей глубокого машинного обучения играет обучающий набор данных.

3. Возможность дополнительного обучения уже сформированных нейронных сетей на новых данных делает их крайне эффективным инструментом при решении конструкторско-инженерных задач.

4. Необходимо применять параметрическое представление профилей лопаток для описания их строения в обучающих наборах данных и при использовании нейронных сетей.

5. Для обеспечения широких обобщающих возможностей нейронных сетей в области газодинамики нужно обеспечить обучающий датасет набором данных с независимо изменяющимися признаками.

СПИСОК ЛИТЕРАТУРЫ

1. **Michelassi V., Ling J.** Challenges and opportunities for artificial intelligence and high-fidelity simulations in turbomachinery applications: A perspective // *J. Global Power Propul. Soc.* 2021. Special Issue. <https://doi.org/10.33737/jgpps/135173>
2. **Паровые** и газовые турбины для электростанций: учеб. для вузов // А.Г. Костюк, В.В. Фролов, А.Е. Булкин, А.Д. Трухний; под ред. А.Г. Костюка. М.: Издательский дом МЭИ, 2016.
3. **Agromayor R., Nord L.O.** Preliminary design and optimization of axial turbines accounting for diffuser performance // *Int. J. Turbomach. Propul. Power.* 2019. V. 4. No. 3. P. 32. <https://doi.org/10.3390/ijtp4030032>
4. **Craig H.R.M., Cox H.J.A.** Performance estimation of axial flow turbines // *Proc. Inst. Mech. Eng.* 1970. V. 185. No. 1. P. 407–424. https://doi.org/10.1243/PIME_PROC_1970_185_048_02
5. **Дейч М.Е., Филлипов Г.А., Лазарев Л.Я.** Атлас профилей решеток осевых турбомашин. М.: Машиностроение, 1965.
6. **Dai R., Chen L., Duan H.** Reducing rotor secondary losses in a turbine stage through endwall airfoil profiling // *J. Mech. Sci. Technol.* 2020. V. 34. No. 2. P. 4917–4924. <https://doi.org/10.1007/s12206-020-2104-1>
7. **Machine learning methods in CFD for turbomachinery: A review** / J. Hammond, N. Pepper, F. Montomoli, V. Michelassi // *Int. J. Turbomach. Propul. Power* 2022. V. 7. Is. 2. P. 16. MDPI. <https://doi.org/10.3390/ijtp7020016>
8. **Грибин В.Г., Нитусов В.В., Медникова Е.В.** Оптимизация геометрических параметров группы ступеней ЦВД и ЦСД мощных паровых турбин // *Теплоэнергетика.* 2012. № 9. С. 63–68.
9. **Future directions of high fidelity CFD for aerothermal turbomachinery analysis and design** / G. Laskowski, J. Kopriva, V. Michelassi, S. Shankaran, U. Paliath, R. Bhaskaran, Q. Wang, C. Talnikar, Z. Wang, F. Jia // *Proc. of the 46th AIAA Fluid Dynamics Conf.* Washington, DC, USA, 13–17 June 2016. P. 3322.
10. **Knowledge-based turbomachinery design system via a deep neural network and multi-output Gaussian process** / J. Chen, C. Liu, L. Xuan, Z. Zhang, Z. Zou // *Knowledge-Based Systems.* 2022. V. 252. No. 10. P. 109352. <https://doi.org/10.1016/j.knsys.2022.109352>
11. <https://www.turbomachinerymag.com/view/ge-integrating-ai-to-enable-performance-informed-gas-turbine-inverse-design>
12. **Batini N., Becattini N., Cascini G.** Turbomachinery design: checking artificial neural networks suitability for design automation // *Proc. Des. Soc.* 2023. V. 3. P. 3651–3660. <https://doi.org/10.1017/pds.2023.366>
13. **Performance prediction and design optimization of turbine blade profile with deep learning method** / Q. Du, Y. Li, L. Yang, T. Liu, D. Zhang, Y. Xie // *Energy. Part A.* 2022. V. 254. P. 124351. <https://doi.org/10.1016/j.energy.2022.124351>
14. **Pierret S., Van den Braembussche R.A.** Turbomachinery blade design using a Navier–Stokes solver and artificial neural network // *Turbomach.* 1999. V. 121. No. 2. P. 326–332. <https://doi.org/10.1115/1.2841318>
15. **Wang Q., Yang L., Rao Y.** Establishment of a generalizable model on a small-scale dataset to predict the surface pressure distribution of gas turbine blades // *Energy.* 2021. V. 214. P. 118878. <https://doi.org/10.1016/j.energy.2020.118878>
16. **Bruni G., Maleki S., Krishnababu S.K.** C(NN)FD – a deep learning framework for turbomachinery CFD analysis. 2023. <https://doi.org/10.1109/TII.2024.3393140>
17. **Галушкин А.И.** Нейронные сети: основы теории. М.: Горячая линия; Телеком, 2017.
18. **Дейч М.Е.** Техническая газодинамика. М.: Госэнергоиздат, 1961.
19. **Дейч М.Е.** Газодинамика решеток турбомашин. М.: Энергоатомиздат, 1996.
20. **Аронов Б.М., Жуковский М.И., Журавлев В.А.** Профилирование лопаток авиационных газовых турбин. М.: Машиностроение, 1975.

21. **Применение** параметрического метода для профилирования межлопаточных каналов сопловых решеток осевых турбомашин / В.Г. Грибин, А.А. Тищенко, Р.А. Алексеев, В.А. Тищенко, И.Ю. Гаврилов, В.В. Попов // Теплоэнергетика. 2020. № 8. С. 50–57. <https://doi.org/10.1134/S0040363620080020>
22. **Snoek J., Larochelle H., Adams, R.P.** Practical Bayesian optimization of machine learning algorithms // Adv. Neural Inform. Proc. Syst. 2012. V. 25. P. 2960–2968. <http://dblp.uni-trier.de/db/conf/nips/nips2012.html#SnoekLA12>
23. **Coull J.D., Hodson H.P.** Blade loading and its application in the mean-line design of low pressure turbines // Proc. of the ASME 2011 Turbo Expo: Turbine Technical Conf. and Exposition. V. 7: Turbomachinery, Parts A, B, and C. Vancouver, British Columbia, Canada, 6–10 June 2011. P. 547–558. <https://doi.org/10.1115/GT2011-45238>
24. **Метод** параметрического представления аэродинамических профилей лопаток осевых турбомашин / В.Г. Грибин, А.А. Тищенко, Р.А. Алексеев, В.А. Тищенко, И.Ю. Гаврилов, В.В. Попов // Теплоэнергетика. 2020. № 7. С. 6–13. <https://doi.org/10.1134/S0040363620070024>
25. **Щегляев А.В.** Паровые турбины. Т. 1: Теория теплового процесса и конструкции турбин. М.: Энергоатомиздат, 1993.
26. **Zhang C., Janeway M.** Optimization of turbine blade aerodynamic designs using CFD and neural network models // Int. J. Turbomach. Propuls. Power. 2022. V. 7. No. 3. P. 20. <https://doi.org/10.3390/ijtpp7030020>
27. **Дейч М.Е., Филиппов Г.А.** Газодинамика двухфазных сред. М.: Энергоиздат, 1981.
28. **Тищенко В.А., Алексеев Р.А.** Численное моделирование процессов образования и движения водяной пленки и эрозионно-опасных капель в проточных частях паровых турбин // Теплоэнергетика. 2019. № 11. С. 72–81. <https://doi.org/10.1134/S0040363619110055>

Determining the Profile Loss of Flow Kinetic Energy in Turbine Cascades with the Use of Neural Networks

V. A. Tishchenko^{a, b}, A. A. Belousova^c, P. M. Nesterov^{a, *}, and A. O. Smirnov^{b, **}

^a National Research University Moscow Power Engineering Institute, Moscow, 111250 Russia

^b Joint Stock Company Power Machines – ZTL, LMZ, Electrosila, Energomachexport, St. Petersburg, 195009 Russia

^c Atomenergoproekt Joint Stock Company, Moscow, 107996 Russia

*e-mail: NesterovPM@mpei.ru

**e-mail: SmirnovAOI@mpei.ru

Abstract—The article addresses matters concerned with the use of neural networks for predicting the gas dynamic characteristics of turbine machinery cascades. The results of elaborating the architecture of deep machine learning models for determining the profile kinetic energy loss downstream of plane nozzle vane and rotor blade (impulse type) turbine cascades are presented. A procedure for preparing the training dataset with using numerical simulation of viscous flows is described. The dataset generated is analyzed; its shortcomings, which should be removed for improving the quality of trainable neural networks are identified. Work on selecting the architecture of neural networks for rotor and nozzle vane cascades was carried out. The studies have shown that the same structure of models is efficient for both nozzle vane and rotor blade cascades. The use of prepared models yielded good agreement between the predicted results and the data available for all types of the cascades considered. It is pointed out that the neural networks yield incorrect predictions in transonic and supersonic operation conditions near the theoretical Mach number downstream of the cascade equal to unity. This stems from the lack of information on such operation conditions in the training dataset. After the models had been additionally trained under supersonic operation conditions, it became possible to “trace” the influence of the flow wave structure on the power performance characteristics downstream of the cascade. The data obtained served as a basis for stating the importance of representing curvilinear blade passages in parametric form and the necessity to prepare the training data in a wide variation range of the majority of independent parameters. The neural networks have demonstrated high-efficient performance in solving the stated problem, which made it possible to formulate a number of algorithmic concepts for applying them in solving turbine stage design problems.

Keywords: neural networks, gas dynamics of turbine machinery cascades, profile energy loss, numerical simulation, turbine stages, theoretical Mach number