

УДК 621.515

doi: 10.18698/0536-1044-2020-7-29-42

Моделирование характеристик безлопаточных диффузоров с помощью нейронных сетей*

Ю.Б. Галеркин¹, А.Г. Никифоров², О.А. Соловьева¹,
Е.Ю. Попова¹, А.В. Рековец²

¹ Объединенный научно-технологический институт ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого»

² ФГБОУ ВО «Смоленская ГСХА»

Simulating Characteristics of Vaneless Diffusers Using Neural Networks

Y.B. Galerkin¹, A.G. Nikiforov², O.A. Solovyeva¹,
E.Y. Popova¹, A.V. Rekovets²

¹ Federal State Autonomous Educational Institution of Higher Education — Peter the Great St. Petersburg Polytechnic University

² Federal State Budgetary Educational Institution of Higher Education – Smolensk State Agricultural Academy

Для расчета параметров потока в безлопаточном диффузоре ступени центробежного компрессора достаточно определить коэффициент потерь и направление потока на выходе. Приведены результаты моделирования характеристик этих двух параметров с помощью нейронных сетей и CFD-методами. Для получения математических моделей использованы данные расчетов характеристик безлопаточных диффузоров по программе ANSYS CFX с относительной шириной 0,014...0,100, относительным диаметром выхода 1,4...2,0, углом входа потока на входе 10...90° и скоростным коэффициентом на входе 0,39...0,82 при числе Рейнольдса 87 500...1 030 000. Сопоставление с положениями теории показало закономерность протекания газодинамических характеристик, а сопоставление с известными экспериментами — соответствие структуры потока. В целях повышения точности моделирования с использованием нейронных сетей собраны и апробированы различные рекомендации по подготовке и обработке исходных данных: выявление конфликтных примеров и выбросов, нормализация данных, повышение качества обучения нейронных сетей при недостаточном объеме выборки и др. Применение указанных рекомендаций существенно повысило точность моделирования. Проведенный на основе нейронных моделей имитационный эксперимент по изучению влияния размеров, формы диффузора и критериев подобия на его газодинамические характеристики позволил проверить физическую адекватность математических моделей, получить новые данные о процессах преобразования энергии и сформулировать рекомендации по оптимальному проектированию безлопаточных диффузоров.

Ключевые слова: ступень центробежного компрессора, безлопаточный диффузор, коэффициент потерь, математическая модель, нейронная сеть

To calculate flow parameters of a vaneless diffuser of the centrifugal compressor stage, it is sufficient to determine the loss coefficient and the flow direction at the outlet. The paper

* Расчеты проведены с использованием суперкомпьютерного центра «Политехнический» СПбПУ. Работа выполнена при поддержке гранта Президента Российской Федерации для молодых кандидатов наук МК-1893.2020.8.

presents the results of modeling the characteristics of these two parameters using neural networks and CFD methods. To obtain mathematical models, ANSYS calculation data was used for vaneless diffusers with a relative width of 0.014–0.1, relative outlet diameter of 1.4–2.0, inlet flow angle of 10–90° and velocity coefficient of 0.39–0.82, with the Reynolds number being in the range of 87 500–1 030 000. A comparison with the theory showed the regularity of gas-dynamic characteristics, and comparison with well-known experiments showed the correspondence of the flow structure. In order to improve the accuracy of simulation using neural networks, various recommendations on the preparation and processing of the initial data were collected and tested: identification of conflict examples and outliers, data normalization, improving the quality of the neural network training under the insufficient amount of sampling, etc. The application of the aforementioned recommendations significantly improved the accuracy of simulation. A simulation experiment based on neural models for studying the influence of dimensions, diffuser shape and similarity criteria on the diffuser gas dynamic characteristics made it possible to verify physical adequacy of the mathematical models, obtain new data on energy conversion processes and produce a set of recommendations on the optimal design of vaneless diffusers.

Keywords: centrifugal compressor stage, vaneless diffuser, loss coefficient, mathematical model, neural network

Уравнения движения газа — это дифференциальные уравнения второго порядка в частных производных, не подлежащие интегрированию, поэтому аналитически описать рабочий процесс центробежных компрессоров невозможно. Для газодинамического проектирования применяют приближенные методы, в основе которых лежат математические модели (ММ). Действительный рабочий процесс схематизируют и описывают системами полуэмпирических уравнений.

Отечественные и зарубежные университеты и заводы — изготовители компрессорного оборудования имеют подобные ММ. Их вид и особенности зависят от применяемых подходов к схематизации процессов.

Школа Невского завода создала основу и внесла главный вклад в отечественную компрессорную науку [1, 2].

Казанская школа компрессоростроения разработала собственную модель, базирующуюся на вычислении потерь в межлопаточных каналах. Расчет проводят по аналогии с эквивалентным диффузором с учетом кривизны канала [3, 4]. Результирующие коэффициенты потерь учитывают влияние чисел Маха и Рейнольдса с помощью эмпирических соотношений. Учет конечного числа лопаток проводится по эмпирической формуле А. Стодолы.

Зарубежные компании также развивают свои методы проектирования [5–8].

В практике газодинамического проектирования промышленных центробежных компрессоров получил признание Метод универсального моделирования (МУМ), разработанный

профессором Ю.Б. Галеркиным. Это комплекс компьютерных программ для оптимального газодинамического проектирования проточной части центробежных компрессоров. С середины 1990-х гг. МУМ постоянно используют в проектной практике [9, 10], совершенствуя его в научно-исследовательской лаборатории «Газовая динамика турбомашин» [11, 12].

В настоящее время с помощью коммерческих программ вычислительной газодинамики невозможно рассчитать характеристики ступени с точностью, достаточной для проектирования. Однако моделирование неподвижных элементов центробежных ступеней дает корректное решение [13–18].

Это сделало возможным заменить экспериментальные исследования неподвижных элементов результатами CFD-расчетов. На основании обобщения результатов вычислений можно создать новые ММ для определения параметров потока в элементах проточной части центробежных компрессоров и использовать их в программах МУМ. Этот подход реализован при построении новой ММ безлопаточных диффузоров (БЛД), применяемой в восьмой версии МУМ [17–19].

Для расчета параметров потока в БЛД достаточно знать любые две из перечисленных величин: коэффициент полезного действия (КПД), коэффициент потерь, коэффициент восстановления, отношение скоростей, угол потока на выходе [20].

Безразмерная газодинамическая характеристика БЛД есть функция его формы, угла потока на выходе, критериев подобия и относитель-

ной шероховатости. Форма БЛД с параллельными стенками определяется относительными шириной на входе $\bar{b}_2 = b_2/D_2$ и диаметром выхода $\bar{D}_4 = D_4/D_2$, где b_2 — ширина БЛД на входе; D_4 — диаметр выхода из БЛД; D_2 — диаметр на входе в БЛД.

Объектами моделирования являлись газодинамические характеристики БЛД. Их обрабатывали двумя разными математическими методами, одним из которых был регрессивный анализ в программе Excel. Процессы обработки расчетных данных и создание соответствующей ММ подробно описаны в работе [20].

Цель работы — создание ММ для расчета газодинамических характеристик БЛД на основании их обработки с помощью нейронных сетей (НС).

Ранее разработанная модель позволяет рассчитать коэффициент потерь ζ БЛД и угол потока на выходе α_4 . Расчетные зависимости КПД η и коэффициента потерь ζ БЛД от угла на входе в БЛД α_2 с относительной шириной $\bar{b}_2 = 0,014$ и $0,100$ при скоростном коэффициенте $\lambda_{c2} = 0,39; 0,64; 0,82$ приведены на рис. 1 [20].

Коэффициент потерь является функцией семи переменных:

$$\zeta = f(\bar{b}_2, \bar{D}_4, \bar{k}_{ш}, \alpha_2, \lambda_{c2}, Re_{b2}, k),$$

где $\bar{k}_{ш}$ — относительная шероховатость; Re_{b2} — число Рейнольдса, рассчитанное по ширине b_2 на входе в БЛД; k — показатель адиабаты.

В общем виде аппроксимирующая зависимость для коэффициента потерь записывается как

$$\zeta = \frac{A\alpha^b K_{D4}}{K_{Re, k_{ш}}},$$

где A и b — зависимости, учитывающие влияние \bar{b}_2 и λ_{c2} на ζ ; α — угол потока на входе в БЛД; K_{D4} — поправка на влияние относительного диаметра БЛД; $K_{Re, k_{ш}}$ — поправки на влияние числа Рейнольдса и относительной шероховатости.

Каждый член данной формулы — это набор алгебраических уравнений. На первом этапе выполнена аппроксимация влияния параметров \bar{b}_2 , α_2 и λ_{c2} на коэффициент потерь при фиксированном относительном диаметре выхода из БЛД $\bar{D}_4 = 1,6$. На втором этапе введена поправка на влияние относительного диаметра БЛД K_{D4} . Поправки на влияние критерия Рейнольдса и относительной шероховатости сделаны на основании известных уравнений гидроаэродинамики:

$$K_{Re} = \frac{\lambda_{расч}}{\lambda_{ММ}} = \frac{0,0032 + \frac{0,221}{(8,73 \cdot 10^6 \cdot \bar{b}_2)^{0,237}}}{0,0032 + \frac{0,221}{Re_b^{0,237}}};$$

$$K_{k_{ш}} = \frac{\lambda_{расч}}{\lambda_{ММ}} = \left[0,0032 + \frac{0,221}{(8,73 \cdot 10^6 \cdot \bar{b}_2)^{0,237}} \right] \times \left(2 \lg \frac{2}{\bar{k}_{ш}} + 1,74 \right)^2,$$

где $\lambda_{расч}$, $\lambda_{ММ}$ — коэффициенты трения, рассчитанные по CFD и по МУМ соответственно.

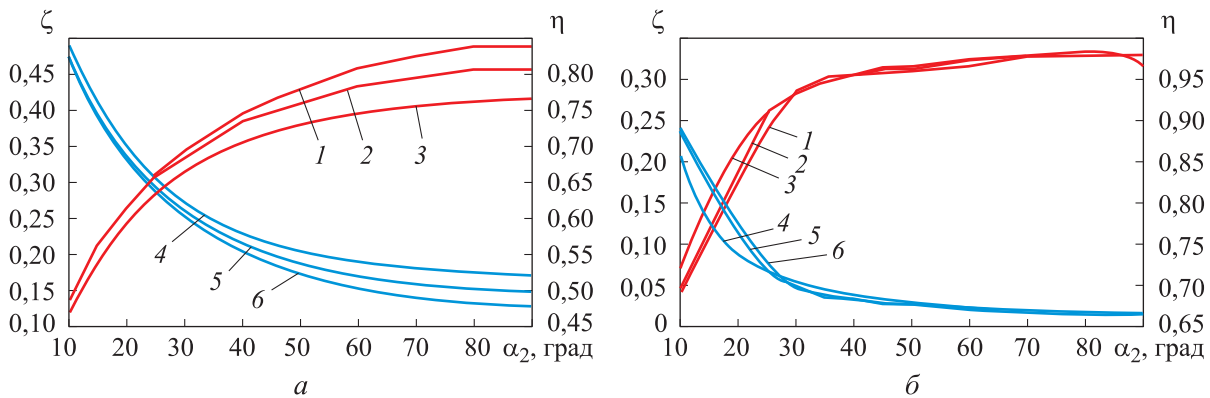


Рис. 1. Расчетные зависимости КПД η (1–3) и коэффициента потерь ζ (4–6) от угла потока на входе в БЛД α_2 с относительной шириной $\bar{b}_2 = 0,014$ (а) и $0,100$ (б) при различных значениях скоростного коэффициента: 1, 6 — $\lambda_{c2} = 0,82$; 2, 5 — $\lambda_{c2} = 0,64$; 3, 4 — $\lambda_{c2} = 0,39$

Аппроксимация расчетных значений угла потока на выходе из БЛД выполнена тем же методом, что и для коэффициента потерь.

Зависимости коэффициента потерь ζ и изменения угла потока в БЛД $\alpha_4 - \alpha_2$ от угла потока на входе в БЛД α_2 при различных значениях параметров \bar{b}_2 , λ_{c2} и \bar{D}_4 приведены на рис. 2 и 3. Здесь сплошные линии — результаты расчета по программе ANSYS CFX, штриховые линии — их аппроксимация.

В качестве альтернативного метода моделирования предлагается использовать НС, кото-

рые, как универсальный аппроксиматор, позволяют сравнительно просто построить обобщенные модели, основанные на обработке большого объема исходных данных. Необходимо специально подчеркнуть, что нейросетевые модели являются простым инструментом для использования в проектной или исследовательской деятельности, не требующим специальной предварительной подготовки. Основные положения, особенности и достоинства нейросетевого подхода при моделировании характеристик центробежных компрессоров приведены в работе [21].

Создание нейросетевой модели. В упрощенном виде можно показать, что НС выполняет аппроксимацию:

$$Y = f(X),$$

где X — входной вектор, представляющий собой набор геометрических и газодинамических параметров; Y — выходной вектор — та или иная искомая характеристика эффективности БЛД, f — преобразование, выполняемое НС.

Накопленная практика построения и анализ использования НС для моделирования характеристик центробежных компрессоров позволяют сделать вывод, что важным этапом построения нейронной модели является предварительная подготовка и обработка исходных данных для обучения НС, которые позволяют существенно повысить точность и достоверность искомых моделей.

В общем случае, для обработки выборки исходных данных и обучения НС можно использовать следующую последовательность этапов, сформированную эмпирически:

- выбор параметров входного вектора:
 - логика и анализ предметной области;
 - анализ весовых коэффициентов входных нейронов;
 - возмущение значений входных параметров и анализ реакции сети на эти возмущения;
 - поочередное исключение входных нейронов и наблюдение за ошибкой обобщения сети;
- выявление конфликтных примеров;
- определение необходимого количества примеров;
- повышение качества обучения НС при недостаточном объеме выборки (многократная перекрестная проверка, кратное повторение




Рис. 2. Расчетные (сплошные линии) и аппроксимирующие (штриховые линии) зависимости коэффициента потерь ζ от угла потока на входе в БЛД α_2 при $\bar{b}_2 = 0,043$, $\lambda_{c2} = 0,64$ и различных значениях относительного диаметра:

—, — — — $\bar{D}_4 = 1,4$; —, — — — $\bar{D}_4 = 1,6$;
—, — — — $\bar{D}_4 = 1,8$; —, — — — $\bar{D}_4 = 2,0$




Рис. 3. Расчетные (сплошные линии) и аппроксимирующие (штриховые линии) зависимости изменения угла потока в БЛД $\alpha_4 - \alpha_2$ от угла потока на входе в БЛД α_2 при $\bar{b}_2 = 0,057$ и различных значениях скоростного коэффициента:

—, — — — $\lambda_{c2} = 0,39$; —, — — — $\lambda_{c2} = 0,64$;
—, — — — $\lambda_{c2} = 0,82$

выборки и изменение порядка следования обучающих примеров);

- выявление выбросов;
- нормализация данных;
- выбор типов НС и активационных функций;
- декомпозиция сети по числу выходных нейронов.

Далее рассмотрим более подробно каждый из этих этапов алгоритма обработки выборки исходных данных для построения НС.

Успех создания нейросетевой модели во многом зависит от выбора входных параметров. Для начала необходимо определить, есть ли реальная зависимость между входным параметром и выходным вектором Y — целью моделирования. В общем случае в исходную выборку могут быть включены параметры, не оказывающие влияния на выходной вектор Y , называемые незначимыми.

Но в большом массиве исходных данных не всегда бывает легко определить, какие параметры окажутся значимыми для модели, а какие можно смело отбросить. Поэтому для начала в подготавливаемую выборку лучше собирать как можно больше параметров, незначительность которых нельзя выявить логическим путем и априори предсказать.

После создания и обучения НС на всем объеме данных, которые удалось получить исследователю, незначимые параметры можно выявить несколькими способами:

- *с помощью анализа значений весовых коэффициентов входных нейронов*; так как НС — это самообучающиеся системы, в процессе обучения веса параметров, мало влияющих на результат, будут ослабевать и становиться значительно меньше по значению, чем веса для остальных параметров; анализ весов НС приведен в работе [21];

- *путем возмущения значений входных параметров и анализа реакции сети на эти возмущения*; после обучения НС искусственно создается входной вектор X , в котором каждый из параметров принимает крайние значения (максимальные и/или минимальные); если сеть не реагирует или слабо реагирует изменением погрешности на возмущения какого-либо параметра, то последний не является значимым и в дальнейшем его можно будет исключить из выборки;

- *с помощью исключения входных нейронов и наблюдения за ошибкой обобщения НС*; если

обученная сеть реагирует на исключение какого-либо нейрона увеличением ошибки обобщения, то параметр, который соответствует этому нейрону, — значимый; иначе параметр является незначимым и впоследствии его можно будет исключить из обучающей выборки.

После выявления и исключения незначимых параметров из обучающей выборки качество и точность нейросетевой модели, как правило, улучшаются, вследствие снижения ее размерности и сложности. Но важно помнить, что чрезмерное уменьшение числа входных параметров и упрощение нейросети могут помешать выявить закономерности в конкретной задаче. Это также может повлечь за собой возникновение конфликтных (противоречивых) примеров.

Примеры называют конфликтным, когда они имеют одинаковые входные векторы и различающиеся выходные векторы. Например, если случайно отбросить значащие параметры при расчете характеристик БЛД, то может сложиться ситуация, когда НС будет вычислять коэффициент потерь ζ по двум параметрам α_2 и λ_{c2} . После обучения на паре данных, например, $4 \cdot 4 = 16$ и $4 \cdot 4 = 24$ сеть усреднит введенные значения и усвоит, что если задан пример $4 \cdot 4$, то ответ $4 \cdot 4 = 20$.

Погрешность обучения при этом составит $\varepsilon_L = [(20 - 16)/16] \cdot 100 \% = 25 \%$. И из-за ошибочно подготовленных данных она уже не опустится ниже этого значения, какие бы методы обучения не применялись. Поиск, выбор и добавление значащих входных параметров позволяет сделать постановку задачи корректной и уменьшить вероятность возникновения конфликтных примеров.

Для успешного моделирования с помощью НС важно обеспечить *необходимое количество обучающих примеров*. Отчасти концепция «чем больше, тем лучше» верна, но важно помнить, что количество примеров влияет на время обучения, и чрезмерное количество примеров приведет к большим затратам машинного времени на настройку НС. В работе [22] приведена формула, с помощью которой можно определить количество примеров обучающего множества

$$Q = 7N_x + 15,$$

где N_x — количество нейронов входного слоя (количество параметров) нейросетевой модели.

На практике зачастую не удается собрать достаточный объем данных для обучения, и возникает необходимость проведения предвари-

тельных манипуляций с выборкой. В определенной степени недостаток исходных данных для построения НС можно компенсировать проведением предварительной обработки выборки. В качестве приемов обработки опробованы: *многократная перекрестная проверка* (multifold cross-validation), *кратное повторение исходной выборки*, подаваемой на вход НС [23, 24], и *изменение порядка следования обучающих примеров*.

Обучающие примеры подаются в НС в произвольном порядке, а не в том, в котором проводились измерения. Это придает ходу обучения более стохастический характер и помогает снизить вероятность попадания в локальные экстремумы.

Исключение выбросов в выборке также помогает повысить точность нейросетевой модели еще до ее создания. За выбросы в исходной выборке принимают значения параметров, которые из-за случайных причин или в силу воздействия человеческого фактора, существенно отличаются по своим значениям от другой сходной информации. Выбросы могут появиться при сборе информации (не там поставленная запятая, и в результате появляется ошибка в значении на порядок) или быть связаны с другими причинами (погрешности измеряющих приборов, сбой в работе оборудования и прочее), что не отражает закономерности изменения параметров в описываемой предметной области.

Присутствие выбросов отрицательно влияет на точность создаваемых моделей. Как и в случае с конфликтными примерами, погрешность, заложенную в выборке еще до этапа обучения, сложно исправить с помощью изменения алгоритмов обучения. В простых случаях выбросы можно обнаружить при внимательном просмотре выборки.

В более сложных многопараметрических зависимостях и больших массивах информации для поиска выбросов можно прибегнуть к использованию НС с минимальным количеством нейронов в скрытом слое. НС перцептронного типа плохо обучается на исходных данных с выбросами и, поочередно убирая примеры и сравнивая получившиеся погрешности, можно обнаружить те значения, которые являются выбросами. Но в случае большого объема выборки это сложно осуществить, поэтому прибегают к различным алгоритмам поиска выбросов [25].

Также информацию, приготовленную для нейросетевой обработки желательно *нормализовать*, приведя диапазон изменения значений величин к общему для всех входных параметров интервалу (например, $[0, 1]$). После нормировки всех данных их значения сводятся к одному порядку размерности. Это позволяет улучшить обучение сети. После моделирования результаты преобразуют обратно: из нормализованных к естественному диапазону значений. Процесс нормализации подробно описан в работах [26–28].

В зависимости от того, какую задачу необходимо решить с помощью нейросетевого моделирования, нужно выбрать тип НС. Так, для аппроксимации функций хорошо подходят НС перцептронного типа, для задач кластеризации часто применяют сети Кохонена, а для распознавания и классификации изображений — сверточные НС [29].

Для повышения точности нейросетевой модели в условиях поставленной задачи необходимо решить вопрос *выбора активационных функций нейронов*. Зачастую рекомендуют брать несимметричные, дифференцируемые функции (например, логическую сигмоиду или гиперболический тангенс). Но в некоторых случаях может получиться так, что в зависимости от условий задачи лучше подойдет пороговая функция. При подборе активационной функции также необходимо учитывать предметную область и задачу моделирования [30].

Для сложных нейросетевых моделей, где аппроксимируются значения сразу нескольких выходных параметров полезно использовать *декомпозицию сети по числу выходных нейронов*. То есть вместо НС с пятью входами и тремя выходами создать три нейросети с пятью входами и одним выходом.

Применение этого приема позволяет снизить общую погрешность моделирования выходных параметров. Каждый нейрон будет настраивать свои веса в соответствии с уменьшением погрешности для моделирования одного выходного параметра, а не подстраиваться сразу к нескольким параметрам выходного вектора. Структуру каждой отдельной сети необходимо оптимизировать отдельно с учетом обеспечения минимизации ошибки для каждой НС.

Рассмотренные приемы применены при создании нейронных моделей коэффициента потерь ζ и изменения угла потока $\alpha_4 - \alpha_2$ в БДД ступени центробежного компрессора. Для по-

строения ММ использованы данные по 24 БЛД различной геометрии, исследованных при нескольких значениях скоростного коэффициента λ_{c2} и угла потока на входе в БЛД α_2 .

Исследования БЛД при различных значениях скоростного коэффициента ($\lambda_{c2} = 0,39; 0,64; 0,82$) позволили получить данные по 72 газодинамическим характеристикам для коэффициента потерь ζ и 33 газодинамическим характеристикам для изменения угла потока $\alpha_4 - \alpha_2$. В каждой из них значения параметров измеряли при 13 значениях угла потока на входе в БЛД ($\alpha_2 = 10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 70, 80, 90^\circ$).

Таким образом, объем выборки исходных данных для построения модели коэффициента потерь ζ составил 936 различных вариантов. Его разбили на обучающее (79 %), контрольное (19 %) и тестовое (2 %) множества, что составило 739, 178 и 19 различных примеров соответственно. Для модели изменения угла потока в БЛД $\alpha_4 - \alpha_2$ объем выборки составил 429 примеров. Для обучающей выборки выделили 386 примеров (90 %), для тестовой выборки — 43 (10 %). Тестовая выборка не участвовала в обучении моделей и использовалась только на последнем этапе для оценки погрешностей моделирования.

Приведенные данные помимо широкого диапазона имеют достаточно плотную детализацию промежуточных значений:

- относительная ширина БЛД на входе $\bar{b}_2 = 0,014; 0,016; 0,019; 0,022; 0,025; 0,029; 0,033; 0,038; 0,043; 0,050; 0,057; 0,066; 0,074; 0,087; 0,100;$
- относительный диаметр выхода из БЛД $\bar{D}_4 = 1,4; 1,6; 1,8; 2,0;$
- угол потока на входе в БЛД $\alpha_2 = 10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 70, 80, 90^\circ;$
- скоростной коэффициент, рассчитанный по входной скорости c_2 , $\lambda_{c2} = 0,39; 0,64; 0,82$.

В соответствии с описанным алгоритмом предварительной обработки данных выполнен анализ предметной области, весовых коэффициентов и реакции сети на вводимые возмущения параметров, а также исключение выбросов и нормализация всех значений.

На основе предварительно обработанной выборки построены нейронные модели в виде обобщенных зависимостей:

- для коэффициента потерь БЛД

$$\zeta = f(\bar{b}_2, \bar{D}_4, \alpha_2, \lambda_{c2});$$

- для изменения угла потока в БЛД

$$\alpha_4 - \alpha_2 = f(\bar{b}_2, \alpha_2, \lambda_{c2}).$$

Для выбора оптимальной архитектуры сети каждой модели созданы НС с разным количеством слоев и нейронов.

В целях выбора функции обучения построены двухслойные НС с 25 нейронами в первом (скрытом) слое. Проверена точность моделирования при изменении функций обучения (train function) с квазиньютоновским методом BFGS, с оптимизацией по Левенбергу — Марквардту и с байесовской регуляризацией.

В первом слое использована активационная функция — логическая сигмоида, во втором — НС с логической сигмоидой (logsig) и линейной активационной функцией (purelin) для каждой функции обучения. После обучения рассчитаны погрешности по каждому типу НС, и в соответствии с минимальной погрешностью выбрана функция обучения с методом оптимизации Левенберга — Марквардта.

Проведен расчетный эксперимент для выбора архитектуры НС. Построены двухслойные модели с числом нейронов в скрытом слое $N = 10, 15, 20, 25, 30$ и одним нейроном в выходном слое. Созданы трехслойные модели с числом нейронов в первом (скрытом) слое $N = 10, 15, 20, 25, 30$ и во втором (скрытом) слое $N = 10, 15, 20, 25, 30$ для каждого варианта числа нейронов в первом слое. В третьем выходном слое один нейрон. Функция активации для всех слоев — логическая сигмоида.

Из теорем Арнольда — Колмогорова — Хехт-Нильсена следует, что для построения нейросетевой модели сколь угодно сложной функции достаточно использовать персептрон с одним скрытым слоем сигмоидных нейронов, количество которых определяется формулами, приведенными далее.

Необходимое число синаптических связей НС N_w определено с помощью следствия из теоремы Арнольда — Колмогорова — Хехт-Нильсена, выраженного в виде формулы

$$\frac{N_y Q}{1 + \log_2 Q} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (1)$$

где N_y — количество нейронов выходного слоя (количество моделируемых величин); Q — количество элементов множества обучающих примеров, т. е. количество пар входных и выходных векторов \mathbf{X}_q и \mathbf{D}_q .

Для модели коэффициента потерь получен диапазон числа синаптических связей $\zeta =$

$= 70 \dots 1115$ ($70 \leq N_w \leq 1115$), для модели изменения угла потока в БЛД — $\alpha_4 - \alpha_2 = 40 \dots 649$ ($40 \leq N_w \leq 649$).

Это позволяет определить необходимое количество нейронов в скрытых слоях. Например, количество нейронов скрытого слоя двухслойного персептрона [22]

$$N = \frac{N_w}{N_x + N_y}. \quad (2)$$

Расчет по формулам (1), (2) показывает, что оптимальное количество нейронов в скрытом слое для двухслойного персептрона модели коэффициента потерь ζ лежит в пределах $14 \dots 223$ нейронов ($14 \leq N \leq 223$), а для модели изменения угла потока в БЛД $\alpha_4 - \alpha_2$ — $10 \dots 162$ нейронов ($10 \leq N \leq 162$).

Строгой теории выбора оптимального количества скрытых слоев и нейронов в них в

настоящее время не существует. На практике чаще всего используют персептроны, имеющие один или два скрытых слоя, где количество нейронов обычно колеблется от $N_x/2$ до $3N_x$.

Расчетный эксперимент на НС показал, что минимальная ошибка соответствует сети, имеющей в скрытом слое 20 нейронов для модели коэффициента потерь ζ и 30 нейронов для модели изменения угла потока в БЛД $\alpha_4 - \alpha_2$. Эти значения соответствуют диапазону, полученному в теоретических расчетах по формулам.

Для моделирования коэффициента потерь ζ выбрана НС со следующей архитектурой: двухслойная, число нейронов в скрытом слое — 20, функции активации — логическая сигмоида для всех слоев, функция обучения — с оптимизацией по алгоритму Левенберга — Марквардта.

Для моделирования изменения угла потока в БЛД $\alpha_4 - \alpha_2$ использована НС со следующей

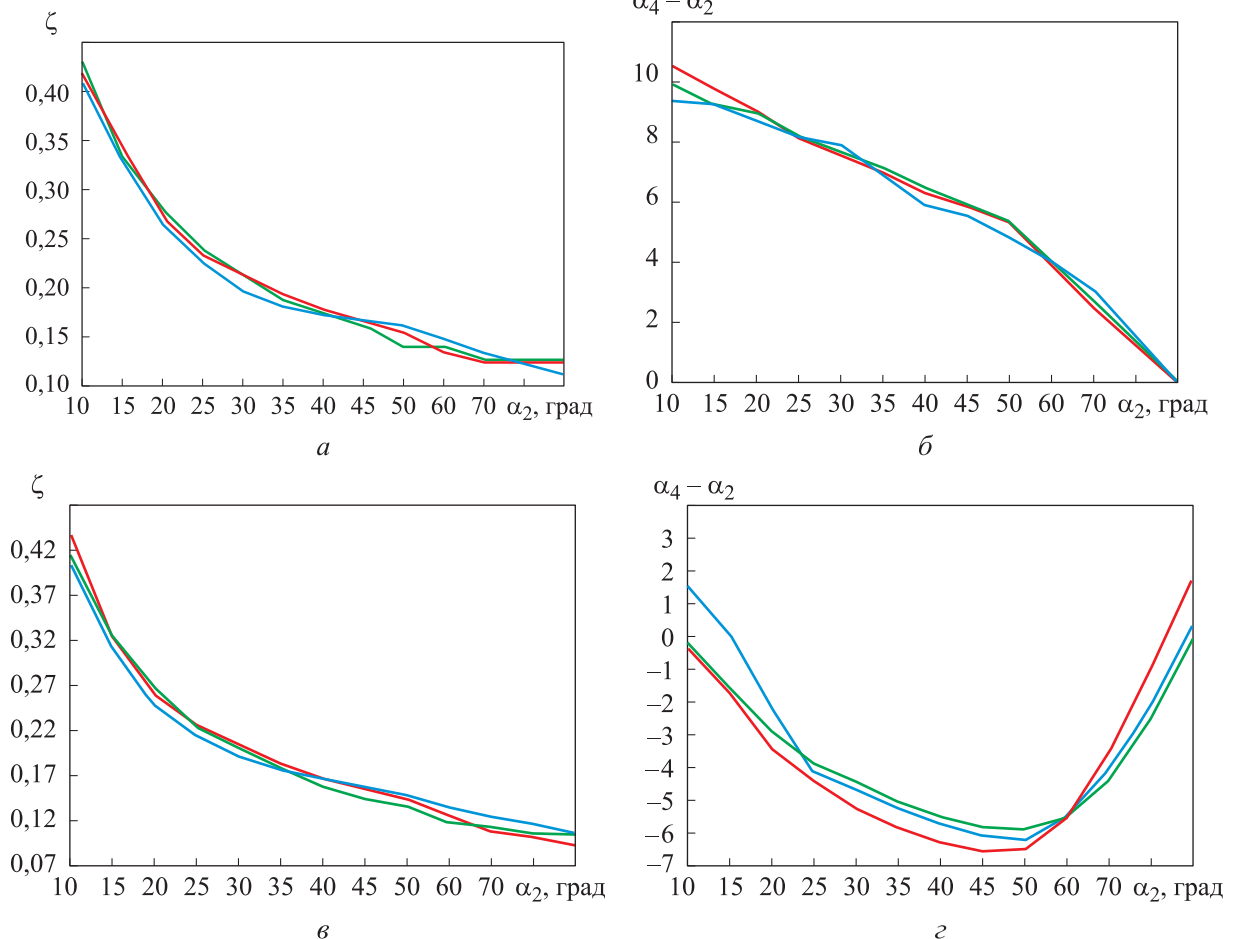


Рис. 4. Расчетные зависимости коэффициента потерь ζ (слева) и изменения угла потока в БЛД $\alpha_4 - \alpha_2$ (справа) от угла потока на входе в БЛД α_2 , полученные с помощью программы ANSYS CFX (—) и нейронной сети для ненормированных (—) и нормированных (—) данных, при $\bar{D}_4 = 1,4$ и различных значениях относительной ширины и скоростного коэффициента:

$$a, б - \bar{b}_2 = 0,014, \lambda_{c2} = 0,39; в - \bar{b}_2 = 0,014, \lambda_{c2} = 0,64; з - \bar{b}_2 = 0,100, \lambda_{c2} = 0,82$$

архитектурой: двухслойная, число нейронов в скрытом слое — 30, функции активации — логическая сигмоида для всех слоев, функция обучения — с оптимизацией по алгоритму Левенберга — Марквардта.

Выбор в пользу двухслойных сетей сделан вследствие незначительной разницы в погрешностях двух- и трехслойной нейросетей. Принята более экономичная с точки зрения вычислительной мощности модель на двух слоях персептрона.

Проверка влияния нормировки проведена путем сравнения сетей, обученных на ненормированных и нормированных данных (рис. 4).

Для ненормированной обучающей выборки средняя ошибка значений модели коэффициента потерь $\zeta = f(\bar{b}_2, \bar{D}_4, \alpha_2, \lambda_{c2})$, рассчитанных нейронной сетью, составила 6,4 %, для нормированной — 2,7 %. Для ненормированной обучающей выборки средняя ошибка расчетных

значений модели изменения угла потока в БЛД $\alpha_4 - \alpha_2 = f(\bar{b}_2, \alpha_2, \lambda_{c2})$ составила 8,3 %, для нормированной — 3,9 %.

Предобработка выборки для обучения НС имеет практическую значимость, так как обеспечивает существенное снижение погрешностей моделирования по сравнению с таковыми у НС, созданных на неподготовленных исходных данных.

Обученные нейросетевые модели позволили провести расчетные исследования, на основании которых можно сделать вывод, что модели физически адекватны. На рис. 5 и 6 приведены расчетные зависимости коэффициента потерь $\zeta = f(\bar{b}_2, \bar{D}_4, \alpha_2, \lambda_{c2})$ и изменения угла потока $\alpha_4 - \alpha_2 = f(\bar{b}_2, \alpha_2, \lambda_{c2})$ в БЛД центробежного компрессора, полученные с помощью НС и программы ANSYS CFX.

На рис. 7 приведены расчетные зависимости коэффициента потерь ζ от угла потока на входе

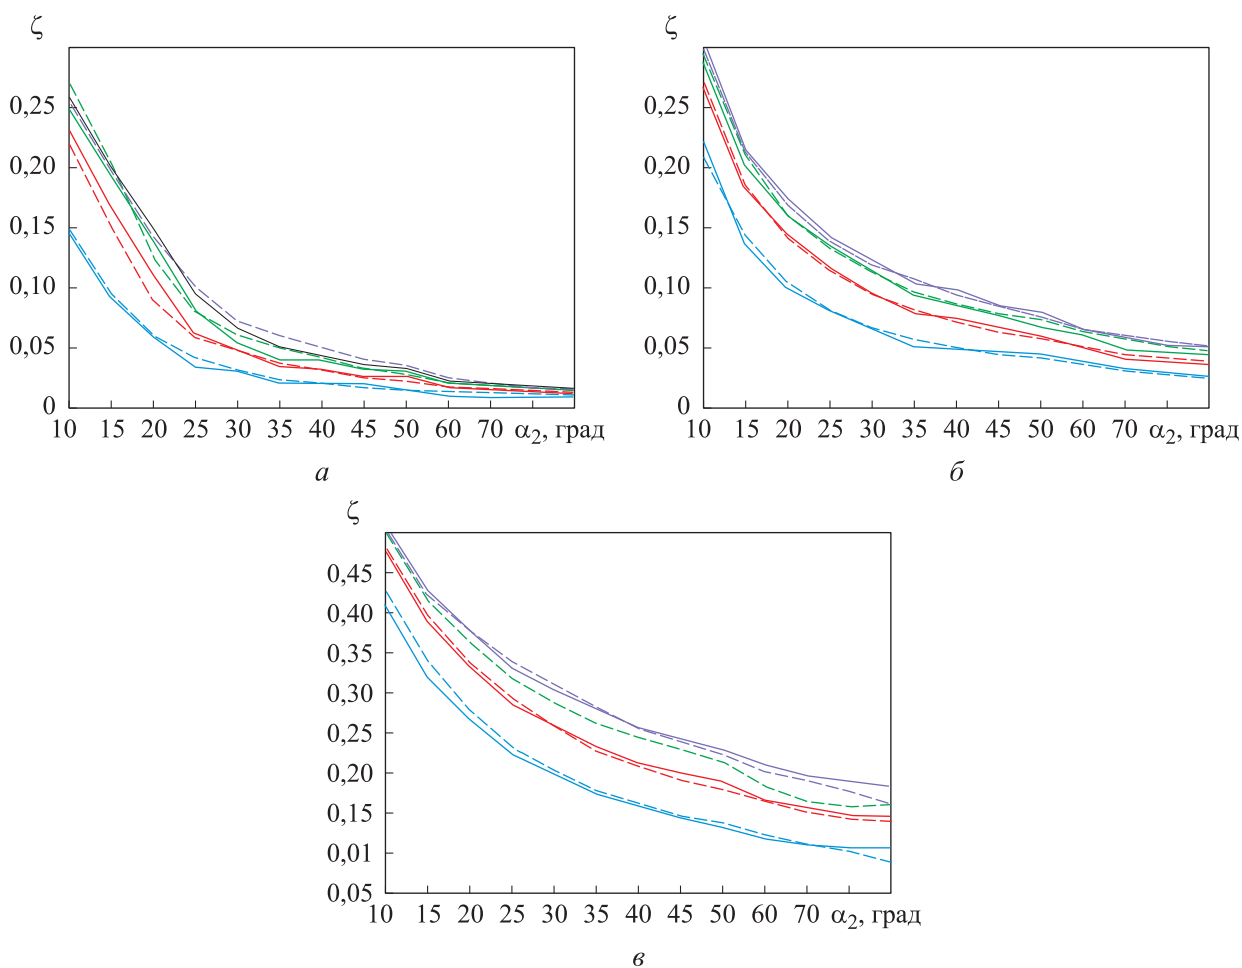


Рис. 5. Расчетные зависимости коэффициента потерь ζ от угла потока на входе в БЛД α_2 , полученные с помощью НС (штриховые линии) и программы ANSYS CFX (сплошные линии), при $\lambda_{c2} = 0,64$, $\bar{b}_2 = 0,100$ (а), $0,043$ (б), $0,014$ (в) и различных значениях относительного диаметра: —, — — $\bar{D}_4 = 1,4$; —, — — $\bar{D}_4 = 1,6$; —, — — $\bar{D}_4 = 1,8$; —, — — $\bar{D}_4 = 2,0$




Рис. 6. Расчетные зависимости изменения угла потока в БЛД $\alpha_4 - \alpha_2$ от угла потока на входе в БЛД α_2 , полученные с помощью НС (штриховые линии) и программы ANSYS CFX (сплошные линии), при $b_2 = 0,014$ (а), $0,057$ (б), $0,100$ (в) и различных значениях скоростного коэффициента:

—, — — $\lambda_{c2} = 0,39$; —, — — $\lambda_{c2} = 0,64$; —, — — $\lambda_{c2} = 0,82$




Рис. 7. Расчетные зависимости коэффициента потерь ζ от угла потока на входе в БЛД α_2 , полученные с помощью НС (точки), программы ANSYS CFX (сплошные линии) и аппроксимирующих выражений (штриховые линии), при $b_2 = 0,043$, $\lambda_{c2} = 0,64$ и различных значениях относительного диаметра:

—, — —, ◆ — $\bar{D}_4 = 1,4$; —, — —, ◆ — $\bar{D}_4 = 1,6$;
—, — —, ◆ — $\bar{D}_4 = 1,8$; —, — —, ◆ — $\bar{D}_4 = 2,0$

в БЛД α_2 , полученные с помощью НС, программы ANSYS CFX и аппроксимирующих выражений, приведенных в работе [20], при $b_2 = 0,043$, $\lambda_{c2} = 0,64$ и $\bar{D}_4 = 1,4; 1,6; 1,8$ и $2,0$.

Хорошее совпадение данных, рассчитанных с помощью НС и CFD-методами, позволяет сделать вывод о пригодности использования НС для моделирования характеристик БЛД.

Выводы

1. Разработана нейросетевая модель для расчета газодинамических характеристик БЛД центробежных компрессорных ступеней.
2. Сформулированы рекомендации по повышению точности нейросетевого моделирования, оформленные в единый алгоритм, состоящий из этапов обработки исходной выборки.
3. Предложенный алгоритм апробирован при моделировании характеристик БЛД центробежной компрессорной ступени.

4. Использование нормирования данных позволило снизить погрешности моделирования коэффициента потерь и изменения угла потока БЛД на 3,7 и 4,4 % соответственно по сравнению с таковыми модели, обученной на ненормированных данных.

5. Полученные результаты моделирования и существенное уменьшение погрешностей нейросетевых моделей показывают важность и необходимость предварительной обработки обучающей выборки.

Литература

- [1] Рис В.Ф. *Центробежные компрессорные машины*. Ленинград, Машиностроение, 1981. 351 с.
- [2] Ден Г.Н. *Проектирование проточной части центробежных компрессоров*. Ленинград, Машиностроение, Ленинградское отделение, 1980. 230 с.
- [3] Шнепп В.Б. *Конструкция и расчет центробежных компрессорных машин*. Москва, Машиностроение, 1995. 240 с.
- [4] Хисамеев И.Г., Максимов В.А., Баткис Г.С., Гузельбаев Я.З. *Проектирование и эксплуатация промышленных центробежных компрессоров*. Казань, ФЭН, 2012. 671 с.
- [5] Aungier R.H. *Centrifugal compressors: a strategy for aerodynamic design and analysis*. New York, ASME Press, 2000. 320 p.
- [6] Japikse D., Krivitzky E.M. Radial stages with non-uniform pressures at diffuser inlet. *Proceedings of the ASME Turbo Expo*, 2016, vol. 2D-2016, doi: 10.1115/GT2016-57956
- [7] Schiff J. *A preliminary design tool for radial compressors*. Thesis for the Degree of Master of Science, LTH Lund University, 2013. 171 p.
- [8] Wang Y., Lin F., Nie C., Engeda A. Design and performance evaluation of a very low flow coefficient centrifugal compressor. *International Journal of Rotating Machinery*, 2013, vol. 2013, no. 293486, doi: 10.1155/2013/293486
- [9] Васильев Ю.С., Родионов П.И., Соколовский М.И. Высокоэффективные центробежные компрессоры нового поколения. Научные основы расчета, разработка методов оптимального проектирования и освоение производства. *Наука и промышленность России*, 2000, № 10–11, с. 78–85.
- [10] Галеркин Ю.Б., Рекстин А.Ф., Солдатова К.В., Дроздов А.А., Попов Ю.А. Развитие научной школы турбокомпрессоростроения ЛПИ-СПбПУ Петра Великого, результаты сотрудничества с компрессоростроителями. *17-я Междунар. науч.-техн. конф. по компрессорной технике*, Казань, 23–24 мая 2017, Казань, 2017, с. 19–29.
- [11] Галеркин Ю.Б. *Турбокомпрессоры. Рабочий процесс, расчет и проектирование проточной части*. Москва, ИИЦ «КХТ», 2010. 596 с.
- [12] Селезнев К.П., Галеркин Ю.Б. *Центробежные компрессоры*. Ленинград, Машиностроение, 1982. 271 с.
- [13] Маренина Л.Н. CFD-моделирование и анализ характеристик неподвижных элементов проточной части центробежной компрессорной ступени. *Компрессорная техника и пневматика*, 2016, № 3, с. 27–35.
- [14] Гамбургер Д.М. *Численное моделирование течения вязкого газа в центробежной компрессорной ступени: методика и результаты*. Санкт-Петербург, СПбГПУ, 2009. 190 с.
- [15] Meduri U.K., Selvam K., Nawrocki G. CFD analysis of centrifugal compressor stage range extension using internal flow recirculation. *Proceedings of the ASME Turbo Expo*, 2015, vol. 2C, doi: 10.1115/GT2015-42592
- [16] Galerkin Y., Voinov I., Drozdov A. Comparison of CFD-calculations of centrifugal compressor stages by NUMECA Fine/Turbo and ANSYS CFX programs. *IOP Conference Series: Materials Science and Engineering*, 2017, vol. 232(1), no. 012044, 12 p., doi: 10.1088/1757-899X/232/1/012044
- [17] Галеркин Ю.Б., Соловьева О.А. Совершенствование методов расчета безлопаточных диффузоров центробежных компрессорных ступеней на основе вычислительных экспериментов. Часть 1. *Компрессорная техника и пневматика*, 2014, № 3, с. 35–41.
- [18] Галеркин Ю.Б., Соловьева О.А. Совершенствование методов расчета безлопаточных диффузоров центробежных компрессорных ступеней на основе вычислительных экспериментов. Часть 2. *Компрессорная техника и пневматика*, 2014, № 3, с. 15–21.
- [19] Rekstin A.F., Drozdov A.A., Solovyeva O.A., Galerkin Y.B. Two mathematical models centrifugal compressor stage vaneless diffuser comparison. *Oil and Gas Engineering. AIP Conf. Proc.*, 2007, Omsk, 2018, pp. 030035-1–030035-12, doi: <https://doi.org/10.1063/1.5051896>

- [20] Соловьева О.А. *Математическая модель для расчета газодинамических характеристик и оптимизации безлопаточных диффузоров центробежных компрессорных ступеней*. Дис. ... канд. техн. наук. Санкт-Петербург, СПбПУ, 2018. 162 с.
- [21] Nikiforov A., Popova D., Soldatova K. A network application for modeling a centrifugal compressor performance map. *IOP Conference Series: Materials Science and Engineering*, 2017, vol. 232(1), no. 012046, doi: 10.1088/1757-899X/232/1/012046
- [22] Ясницкий Л.Н. *Интеллектуальные системы*. Москва, Лаборатория знаний, 2016. 221 с.
- [23] Казанцев П.А. *Разработка и исследование маршрута проектирования нейросетевого приложения с аппаратной поддержкой*. Дис. ... канд. техн. наук. Москва, МФТИ, 2008. 117 с.
- [24] Дагаева М.В., Сулейманов М.А., Катасева Д.В., Катасев А.С., Кирпичников А.П. Технология построения отказоустойчивых нейросетевых моделей распознавания рукописных символов в системах биометрической аутентификации. *Вестник Технологического университета*, 2018, т. 21, № 2, с. 133–138.
- [25] Шкодырев В.П., Ягафаров К.И., Баштовенко В.А., Ильина Е.Э. Обзор методов обнаружения аномалий в потоках данных. *Труды конференции по программной инженерии и информационному управлению*, Санкт-Петербург, Россия, 2017, т. 1864. 7 с.
- [26] Jayalakshmi T., Santhakumaran Dr.A. Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 2011, vol. 3, no. 1, pp. 89–93.
- [27] Ogasawara E., Martinez L.C., De Oliveira D., Zimbrão G., Pappa G.L., Mattoso M. Adaptive Normalization: A Novel Data Normalization Approach for Non-Stationary Time Series. *Proceedings of the International Joint Conference on Neural Networks*, 2010, no. 5596746, doi: 10.1109/IJCNN.2010.5596746
- [28] Nayak S.C., Misra B.B., Behera H.S. Impact of Data Normalization on Stock Index Forecasting. *International Journal of Computer Information Systems and Industrial Management Applications*, 2014, vol. 6, pp. 257–269.
- [29] Осовский С. *Нейронные сети для обработки информации*. Москва, Финансы и статистика, 2002. 344 с.
- [30] Борисов В.В., Федулов А.С., Зернов М.М. *Основы гибридизации нечетких моделей*. Москва, Горячая линия-Телеком, 2017. 100 с.

References

- [1] Ris V.F. *Tsentrobezhnyye kompressornyye mashiny* [Centrifugal compressor machines]. Leningrad, Mashinostroyeniye publ., 1981. 351 p.
- [2] Den G.N. *Proyektirovaniye protochnoy chasti tsentrobezhnykh kompressorov* [Design of the flow part of centrifugal compressors]. Leningrad, Mashinostroyeniye, Leningradskoye otdeleniye publ., 1980. 230 p.
- [3] Shnepp V.B. *Konstruktsiya i raschet tsentrobezhnykh kompressornykh mashin* [Design and calculation of centrifugal compressor machines]. Moscow, Mashinostroyeniye publ., 1995. 240 p.
- [4] Khisameyev I.G., Maksimov V.A., Batkis G.S., Guzel'bayev Ya.Z. *Proyektirovaniye i ekspluatatsiya promyshlennykh tsentrobezhnykh kompressorov* [Design and operation of industrial centrifugal compressors]. Kazan, Fen publ., 2012. 671 p.
- [5] Aungier R.H. *Centrifugal compressors: a strategy for aerodynamic design and analysis*. New York, ASME Press, 2000. 320 p.
- [6] Japikse D., Krivitzky E.M. Radial stages with non-uniform pressures at diffuser inlet. *Proceedings of the ASME Turbo Expo*, 2016, vol. 2D-2016, doi: 10.1115/GT2016-57956
- [7] Schiff J. *A preliminary design tool for radial compressors*. Thesis for the Degree of Master of Science, LTH Lund University, 2013. 171 p.
- [8] Wang Y., Lin F., Nie C., Engeda A. Design and performance evaluation of a very low flow coefficient centrifugal compressor. *International Journal of Rotating Machinery*, 2013, vol. 2013, no. 293486, doi: 10.1155/2013/293486
- [9] Vasil'yev Yu.S., Rodionov P.I., Sokolovskiy M.I. New generation high performance centrifugal compressors. Scientific principles of calculation, development of optimal design methods and production development. *Nauka i promyshlennost' Rossii*, 2000, no. 10–11, pp. 78–85 (in Russ.).
- [10] Galerkin Yu.B., Rekstin A.F., Soldatova K.V., Drozdov A.A., Popov Yu.A. Development of the scientific school of turbocompressor engineering LPI-SPbPU of Peter the Great, the re-

- sults of cooperation with compressor builders. *17-aya Mezhdunar. nauch.-tekhn. konf. po kompressornoy tekhnike* [17th International Scientific and Technical Conference on Compressor Engineering]. Kazan, 2017, pp. 19–29.
- [11] Galerkin Yu.B. *Turbokompressory. Rabochiy protsess, raschet i proyektirovaniye protochnoy chasti* [Turbochargers. Workflow, calculation and design of the flow part]. Moscow, KKHT publ., 2010. 596 p.
- [12] Seleznev K.P., Galerkin Yu.B. *Tsentrobezhnyye kompressory* [Centrifugal compressors.]. Leningrad, Mashinostroyeniye publ., 1982. 271 p.
- [13] Marenina L.N. CFD Wind Tunnel Tests of Centrifugal Stage Return Channel Vane Cascades. *Kompressornaya tekhnika i pnevmatika*, 2016, no. 3, pp. 27–35 (in Russ.).
- [14] Gamburger D.M. *Chislennoye modelirovaniye techeniya вязкого газа v tsentrobezhnoy kompressornoy stupeni: metodika i rezul'taty* [Numerical modeling of viscous gas flow in a centrifugal compressor stage: methodology and results]. Sankt-Petersburg, SPbGPU publ., 2009. 190 p.
- [15] Meduri U.K., Selvam K., Nawrocki G. CFD analysis of centrifugal compressor stage range extension using internal flow recirculation. *Proceedings of the ASME Turbo Expo*, 2015, vol. 2C, doi: 10.1115/GT2015-42592
- [16] Galerkin Y., Voinov I., Drozdov A. Comparison of CFD-calculations of centrifugal compressor stages by NUMECA Fine/Turbo and ANSYS CFX programs. *IOP Conference Series: Materials Science and Engineering*, 2017, vol. 232(1), no. 012044, doi: 10.1088/1757-899X/232/1/012044
- [17] Galerkin Yu.B., Solov'yeva O.A. Improvement of vaneless diffuser calculations based on CFD experiment. *Kompressornaya tekhnika i pnevmatika*, 2014, no. 3, pp. 35–41 (in Russ.).
- [18] Galerkin Yu.B., Solov'yeva O.A. Improvement of vaneless diffuser calculations based on CFD experiment. *Kompressornaya tekhnika i pnevmatika*, 2014, no. 3, pp. 15–21 (in Russ.).
- [19] Rekestin A.F., Drozdov A.A., Solovyeva O.A., Galerkin Y.B. Two mathematical models centrifugal compressor stage vaneless diffuser comparison. *Oil and Gas Engineering. AIP Conf. Proc.*, 2007, Omsk, 2018, pp. 030035-1–030035-12, doi: <https://doi.org/10.1063/1.5051896>
- [20] Solov'yeva O.A. *Matematicheskaya model' dlya rascheta gazodinamicheskikh kharakteristik i optimizatsii bezlopatochnykh diffuzorov tsentrobezhnykh kompressornykh stupeney*. Kand. Diss. [A mathematical model for calculating the gas-dynamic characteristics and optimizing the bezelobnyh diffusers of centrifugal compressor stages. Cand. Diss.]. Sankt-Petersburg, 2018. 162 p.
- [21] Nikiforov A., Popova D., Soldatova K. A network application for modeling a centrifugal compressor performance map. *IOP Conference Series: Materials Science and Engineering*, 2017, vol. 232(1), no. 012046, doi: 10.1088/1757-899X/232/1/012046
- [22] Yasnitskiy L.N. *Intellektual'nyye sistemy* [Intelligent systems]. Moscow, Laboratoriya znaniy publ., 2016. 221 p.
- [23] Kazantsev P.A. *Razrabotka i issledovaniye marshruta proyektirovaniya neyrosetevogo prilozheniya s apparatnoy podderzhkoy*. Kand. Diss. [Development and research of a design route for a neural network application with hardware support. Cand. Diss.]. Moscow, 2008. 117 p.
- [24] Dagayeva M.V., Suleymanov M.A., Kataseva D.V., Katasev A.S., Kirpichnikov A.P. Technology of construction of fault-tolerant neural-network handwriting recognition models in biometric authentication systems. *Vestnik Tekhnologicheskogo universiteta*, 2018, vol. 21, no. 2, pp. 133–138 (in Russ.).
- [25] Shkodyrev V.P., Yagafarov K.I., Bashtovenko V.A., Il'ina E.E. Overview of Anomaly Detection Methods in Data Streams. *Trudy konferentsii po programmnoy inzhenerii i informatsionnomu upravleniyu* [Proc. of the Second Conference on Software Engineering and Information Management]. Sankt-Petersburg, 2017, vol. 1864. 7 p.
- [26] Jayalakshmi T., Santhakumaran Dr.A. Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 2011, vol. 3, no. 1, pp. 89–93.
- [27] Ogasawara E., Martinez L.C., De Oliveira D., Zimbrão G., Pappa G.L., Mattoso M. Adaptive Normalization: A Novel Data Normalization Approach for Non-Stationary Time Series. *Proceedings of the International Joint Conference on Neural Networks*, 2010, no. 5596746, doi: 10.1109/IJCNN.2010.5596746
- [28] Nayak S.C., Misra B.B., Behera H.S. Impact of Data Normalization on Stock Index Forecasting. *International Journal of Computer Information Systems and Industrial Management Applications*, 2014, vol. 6, pp. 257–269.

- [29] Osovskiy S. *Neyronnyye seti dlya obrabotki informatsii* [Neural networks for information processing]. Moscow, Finansy i statistika publ., 2002. 344 p.
- [30] Borisov V.V., Fedulov A.S., Zernov M.M. *Osnovy gibridizatsii nechetkikh modeley* [Basics of hybridization of fuzzy models]. Moscow, Goryachaya liniya-Telekom publ., 2017. 100 p.

Статья поступила в редакцию 17.02.2020

Информация об авторах

ГАЛЕРКИН Юрий Борисович — доктор технических наук, профессор, заведующий НИЛ «Газовая динамика турбомашин». Объединенный научно-технологический институт ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого», почетный председатель Ассоциации компрессорщиков и пневматиков (195251, Санкт-Петербург, Российская Федерация, ул. Политехническая, д. 29, e-mail: yuri_galerkin@mail.ru).

НИКИФОРОВ Александр Георгиевич — доктор технических наук, профессор, зав. кафедрой механизации. ФГБОУ ВО «Смоленская ГСХА» (21400, Смоленск, Российская Федерация, ул. Большая Советская, д. 10/2, e-mail: nikiforof@mail.ru).

СОЛОВЬЕВА Ольга Александровна — кандидат технических наук, научный сотрудник НИЛ «Газовая динамика турбомашин». Объединенный научно-технологический институт ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Санкт-Петербург, Российская Федерация, ул. Политехническая, д. 29, e-mail: Solovyeva.OA@yandex.ru).

ПОПОВА Елена Юрьевна — кандидат технических наук, специалист по учебно-методической работе института среднего профессионального образования. ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Санкт-Петербург, Российская Федерация, ул. Политехническая, д. 29, e-mail: e.popova@list.ru).

РЕКОВЕЦ Андрей Васильевич — кандидат технических наук, доцент кафедры механизации. ФГБОУ ВО «Смоленская ГСХА» (21400, Смоленск, Российская Федерация, ул. Большая Советская, д. 10/2, e-mail: rekovets.andrey@mail.ru).

Information about the authors

GALERKIN Yuri Borisovich — Doctor of Science (Eng.), Professor, Research Laboratory for Gas Dynamics of Turbomachines. Federal State Autonomous Educational Institution of Higher Education — Peter the Great St. Petersburg Polytechnic University, Honorary Chairman, Association of Compressor and Pneumatic Engineers (195251, St. Petersburg, Russian Federation, Politekhnikeskaya St., Bldg. 29, e-mail: yuri_galerkin@mail.ru).

NIKIFOROV Aleksandr Georgievich — Doctor of Science (Eng.), Professor, Head of Department of Mechanization. Federal State Budgetary Educational Institution of Higher Education — Smolensk State Agricultural Academy (21400, Smolensk, Russian Federation, Bolshaya Sovetskaya St., Bldg. 10/2, e-mail: nikiforof@mail.ru).

SOLOVYEVA Olga Aleksandrovna — Candidate of Science (Eng.), Researcher, Research Laboratory for Gas Dynamics of Turbomachines. Federal State Autonomous Educational Institution of Higher Education — Peter the Great St. Petersburg Polytechnic University (195251, St. Petersburg, Russian Federation, Politekhnikeskaya St., Bldg. 29, e-mail: Solovyeva.OA@yandex.ru).

POPOVA Elena Yurievna — Candidate of Science (Eng.), Learning and Methodology Specialist, Institute of Vocational Education at the Federal State Autonomous Educational Institution of Higher Education — Peter the Great St. Petersburg Polytechnic University (195251, St. Petersburg, Russian Federation, Politekhnikeskaya St., Bldg. 29, e-mail: e.popova@list.ru).

REKOVETS Andrei Vasilievich — Candidate of Science (Eng.), Associate Professor, Department of Mechanization. Federal State Budgetary Educational Institution of Higher Education — Smolensk State Agricultural Academy (21400, Smolensk, Russian Federation, Bolshaya Sovetskaya St., Bldg. 10/2, e-mail: rekovets.andrey@mail.ru).

Просьба ссылаться на эту статью следующим образом:

Галеркин Ю.Б., Никифоров А.Г., Соловьева О.А., Попова Е.Ю., Рековец А.В. Моделирование характеристик безлапаточных диффузоров с помощью нейронных сетей. *Известия высших учебных заведений. Машиностроение*, 2020, № 7, с. 29–42, doi: 10.18698/0536-1044-2020-7-29-42

Please cite this article in English as:

Galerkin Y.B., Nikiforov A.G., Solovyeva O.A., Popova E.Y., Rekovets A.V. Simulating Characteristics of Vaneless Diffusers Using Neural Networks. *BMSTU Journal of Mechanical Engineering*, 2020, no. 7, pp. 29–42, doi: 10.18698/0536-1044-2020-7-29-42