



DOI: 10.18721/JEST.24406
УДК 621.51(06)

А.Г. Никифоров¹, Д.Ю. Авраменко²

1 – Смоленская сельскохозяйственная академия, г. Смоленск, Россия

2 – филиал ФГБОУ ВО НИУ «МЭИ» в г. Смоленске, г. Смоленск, Россия

ПОДГОТОВКА ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ ДЛЯ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ ХАРАКТЕРИСТИК ЦЕНТРОБЕЖНЫХ КОМПРЕССОРОВ

Представлена обобщенная информация о возможных видах предварительной обработки исходных данных и эффективности такой обработки для обучения моделей, основанных на нейронных сетях. В зависимости от задач моделирования и особенностей предметной области могут быть выбраны различные сочетания обработки исходной выборки, а также различные виды активационных функций и архитектуры нейронных сетей. Эффективность предобработки исходных данных показана на нейросетевых моделях энергетических характеристик центробежных компрессоров. Исключение выбросов в выборке и нормализация исходных данных позволили повысить точность модели на 1,5 % по сравнению с моделью, обученной на ненормализованных данных. Актуальность обработки и подготовки данных подтверждают работы зарубежных коллег, которые используют предобработку данных для создания нейросетевых моделей в различных предметных областях.

Ключевые слова: искусственные нейронные сети, нейронные сети, центробежный компрессор, коэффициент потерь, коэффициент трения, КПД, напор, промежуточная ступень, безлопаточный диффузор.

Ссылка при цитировании:

А.Г. Никифоров, Д.Ю. Авраменко. Подготовка экспериментальных данных для нейросетевого моделирования характеристик центробежных компрессоров // Научно-технические ведомости СПбПУ. Естественные и инженерные науки. 2018. Т. 24. № 4. С. 61–71. DOI: 10.18721/JEST.24406.

A.G. Nikiforov¹, D.Yu. Avramenko²

1 – Smolensk agricultural academy, Smolensk, Russia

2 – The Smolensk branch of the Moscow power engineering institute, Smolensk, Russia

PREPARING EXPERIMENTAL DATA FOR NEURAL NETWORK MODELING OF CENTRIFUGAL COMPRESSOR PERFORMANCE

The paper presents generalized information on possible methods for preliminary processing of initial data and the efficiency of these methods for training neural network models. Different combinations for processing the initial sample, as well as different types of activation functions and architecture of neural networks can be selected depending on the simulation goals and the specifics of the subject area. The efficiency of preliminary data processing has been established with neural network models of energy characteristics of centrifugal compressors. Eliminating outliers in the experimental data and normalizing the initial data allowed to increase the accuracy of the model by 1,5 % compared with the model trained on non-normalized data. The importance of processing and preparing data is confirmed by findings of foreign studies using data preprocessing to create neural network models in different subject areas.

Keywords: artificial neural networks, neural networks, centrifugal compressors, loss coefficient, friction coefficient, efficiency, pressure, intermediate centrifugal compressor stage, vaneless diffuser.

Citation:

A.G. Nikiforov, D.Yu. Avramenko, Preparing experimental data for neural network modeling of centrifugal compressor performance, *St. Petersburg polytechnic university journal of engineering science and technology*, 24(04)(2018) 61–71, DOI: 10.18721/JEST.24406.

Введение

Проектирование и моделирование характеристик центробежных компрессоров опирается на многолетние разработки ученых всего мира [1–9], тем не менее до сих пор существует ряд проблем при создании математических моделей традиционными способами [10]. Методы, основанные на теории подобия и анализе газодинамических процессов в проточной части компрессора, предполагают проведение многочисленных экспериментальных и доводочных испытаний компрессорной техники; в ходе таких испытаний собран большой объем информации, который можно также использовать для моделирования с помощью нейронных сетей. Нейронные сети как универсальный аппроксиматор позволяют построить обобщенные модели, основанные на большом объеме данных. Основные положения, особенности и достоинства нейросетевого подхода при моделировании характеристик центробежных компрессоров приведены в работе [10]. В упрощенном виде можно показать, что нейронная сеть выполняет аппроксимацию $Y = f(X)$, где X – входной вектор, Y – выходной вектор, f – преобразование, выполняемое нейронной сетью.

Применение нейронных сетей для моделирования энергетических характеристик элементов центробежного компрессора показало, что максимальное отклонение расчетных значений от экспериментальных для политропного КПД и коэффициента напора не превышает 4 % по всему диапазону расходов, а на оптимальных режимах не превышает 1 %. Получены также нейросетевые модели условного коэффициента трения и коэффициента потерь безлопаточного диффузора (БЛД), в которых ошибка аппроксимации составила менее 3 % [11, 12].

Практика использования нейронных сетей для моделирования характеристик центробежных компрессоров привела к выводу, что ана-

лиз, отбор и предобработка обучающих примеров перед обучением нейронных сетей позволяют повысить точность и достоверность моделей.

Цель нашей работы – обобщить накопленный опыт моделирования энергетических характеристик центробежных компрессоров и дать рекомендации по методике предварительной обработки экспериментальных данных для повышения точности результатов нейросетевого моделирования.

В общем случае для обработки выборки исходных данных авторы предлагают исследователям использовать последовательность этапов, которую они сформировали эмпирически.

1. Выбор входных параметров, включающий:

- а) логику и анализ предметной области;
- б) анализ весовых коэффициентов входных нейронов;
- в) возмущение значений входных параметров и анализ реакции сети на эти возмущения;
- г) поочередное исключение входных нейронов и наблюдение за ошибкой обобщения сети.

2. Выявление конфликтных примеров.

3. Определение необходимого количества примеров.

4. Повышение качества обучения нейронных сетей при недостаточном объеме выборки (многократная перекрестная проверка, кратное повторение выборки и изменение порядка следования обучающих примеров).

5. Выявление выбросов.

6. Нормализация данных.

7. Добавление шума в обучающие примеры.

8. Выбор типов нейронных сетей и активационных функций.

9. Декомпозиция сети по числу выходных нейронов.

Остановимся подробнее на каждом пункте.

Успех создания нейросетевой модели во многом зависит от выбора входных параметров. Для начала необходимо определить, есть

ли реальная зависимость между параметром и желаемым выходным вектором Y — целью собственно моделирования. Например, фазы луны несомненно влияют на живую природу, в особенности на приливы и отливы морей и океанов. Но очевидно, что для определения энергетических характеристик центробежного компрессора этот параметр не нужен. Если влияние и будет, то ничтожно малое. Такие параметры называют незначимыми, так как они не оказывают влияния на значение выходного вектора Y . Но не всегда 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 нейронной сети на всем объеме данных, которые удалось получить исследователю, незначимые параметры можно выявить несколькими способами:

с помощью анализа значений весовых коэффициентов входных нейронов. Поскольку нейронные сети это самообучающиеся системы, то в процессе обучения веса параметров, мало влияющих на результат, будут ослабевать и становиться значительно меньше по значению, чем веса остальных параметров;

с помощью возмущения значений входных параметров и анализа реакции сети на эти возмущения. После обучения нейронной сети 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 этот параметр не является значимым, и в дальнейшем его можно будет исключить из выборки;

с помощью исключения входных нейронов и наблюдения за ошибкой обобщения сети. Если

обученная сеть реагирует на исключение какого-либо нейрона увеличением ошибки обобщения, то параметр, который соответствует этому нейрону, является значимым. Если иначе — параметр не является значимым, 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, улучшается вследствие снижения ее размерности и сложности. Но важно помнить, что чрезмерное уменьшение числа входных параметров и упрощение нейросети может помешать выявить закономерности в конкретной задаче. Кроме того, это может повлечь за собой возникновение *конфликтных (противоречивых) примеров*.

Примеры называют конфликтными, когда они имеют одинаковые входные векторы, но различающиеся выходные. Например, если мы случайно отбросили значащие параметры при расчете характеристик компрессора, то может сложиться ситуация, когда нейронная сеть будет вычислять объемный расход $\bar{V} = \varphi_n u_n \pi (r_n^2 - r_{вт}^2)$ по двум параметрам: коэффициенту расхода φ_n и окружной скорости на наружном радиусе лопатки u_n . После обучения на паре данных, например $4 \cdot 4 = 16$ и $4 \cdot 4 = 24$, нейронная сеть усреднит введенные значения и усвоит, что если подается пример $4 \cdot 4$, то ответ — $4 \cdot 4 = 20$. Погрешность обучения при этом составит $\varepsilon_L = \frac{20-16}{16} \times 100\% = 25\%$. И из-за ошибочно подготовленных данных погрешность уже не опустится ниже этой величины, какие бы мы методы обучения не применяли.

Наличие конфликтных примеров в обучающем множестве может быть из-за ошибки (как проиллюстрировано выше) или в случае некорректной постановки задачи. Для оценки наличия и степени гололеда, помимо параметра «температура», нам необходимо знать еще и значения параметров «влажность», «осадки».

Отрицательные значения параметра «температура» не всегда будут соответствовать состоянию «гололед» на дорогах. Поиск, выбор и добавление значащих входных параметров позволяют сделать постановку задачи корректной и уменьшить вероятность возникновения конфликтных примеров.

Для успешного моделирования с помощью нейронных сетей 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 обучение нейронной сети. В [13] приведена формула, с помощью которой можно определить объем обучающей выборки:

$$Q = 7N_x + 15,$$

где N_x – количество входных параметров нейросетевой модели; Q – количество примеров обучающего множества.

На практике зачастую не удается собрать достаточный объем данных для обучения, и возникает необходимость более тщательного тестирования нейронной сети или проведения определенных манипуляций с выборкой.

Как к одному из способов можно прибегнуть к *многократной перекрестной проверке (multifold cross-validation)*. Также с проблемой малой выборки можно справиться путем *кратного повторения исходной выборки*, подаваемой на вход нейронной сети, [14, 15] и изменяя *порядок следования обучающих примеров*. Обучающие примеры подаются в нейронную сеть в произвольном порядке, а не в том, в котором производились измерения. Это придает ходу обучения более стохастический характер и помогает снизить вероятность попадания в локальные экстремумы.

Исключение выбросов в выборке поможет увеличить точность нейросетевой модели еще до ее создания. За выбросы в исходной выбор-

ке принимают значения параметров, которые из-за случайных причин или в силу человеческого фактора существенно отличаются по своим значениям от другой сходной информации. Выбросы могут появиться при сборе информации (например, не там поставленная запятая и ошибка в значении на порядок) или быть связаны с другими причинами (погрешности измеряющих приборов, сбои 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 простейших случаях выбросы можно обнаружить при внимательном просмотре выборки; в более сложных многопараметрических зависимостях и больших массивах информации для поиска выбросов можно прибегнуть к использованию простейших нейронных сетей с минимальным количеством нейронов в скрытом слое. Например, персептрон плохо обучается на примерах с выбросами, но, поочередно убирая примеры и сравнивая получившиеся погрешности, можно обнаружить те примеры, что являются выбросами. Примеры, при исключении которых погрешность будет значительно уменьшаться, не соответствуют общей закономерности и являются выбросами. Однако в случае большого объема выборки это сложно осуществить, поэтому прибегают к различным алгоритмам поиска выбросов [16].

Нейронная сеть способна обрабатывать только числа. Поэтому, если необходимо обработать качественные данные (например, самочувствие – «плохо», «нормально», «хорошо»), то их необходимо закодировать в числовом виде (соответственно: «плохо» – 1, «нормально» – 2, «хорошо» – 3). Информацию,



приготовленную для нейросетевой обработки, можно также *нормализовать*, выровняв диапазон изменения значений величин, ограничив их интервалом (например, $[0, 1]$). Нормализуют входные и выходные сигналы. Важно при нормализации заложить некоторый запас, чтобы в случае, когда новые данные выходят за границы предыдущих максимальных значений, не приходилось каждый раз заново проводить обучение. После моделирования ответы нейронной сети преобразуют обратно, из нормализованных к естественному диапазону значений. Процесс нормализации подробно описан в работах [13, 22–24].

Для систем, сигналы на которые поступают непосредственно с датчиков и приборов, при поиске способов повышения точности модели может быть актуальным *добавление шума в обучающие примеры*. Это позволит улучшить обобщающие свойства сети, снизив ее чувствительность к разновидностям входных сигналов с искажениями, если они находятся в допустимых пределах. Но этот способ лучше применять при большом объеме обучающих множеств (более 300 элементов), чтобы нейронная сеть могла компенсировать введение шумов, а не целиком обучалась на зашумленных примерах.

В зависимости от того, какую задачу необходимо решить с помощью нейросетевого моделирования, можно выбрать тип нейронной сети. Так, для аппроксимации функций хорошо подходят нейронные сети персептронного типа, для задач кластеризации – сети Кохонена, а для распознавания и классификации изображений чаще используют свёрточные нейронные сети [17–19].

Для повышения точности нейросетевой модели в условиях поставленной задачи можно также исследовать вопрос *выбора активационных функций нейронов*. Зачастую рекомендуют брать несимметричные, дифференцируемые функции (например, такие, как логическая сигмоида, гиперболический тангенс). Но

в некоторых случаях может оказаться, что в зависимости от условий задачи лучше подойдет пороговая функция. При подборе активационной функции необходимо также учитывать предметную область и задачу моделирования [20, 21].

Для сложных нейросетевых моделей, где аппроксимируется значение сразу нескольких выходных параметров, может быть полезно использовать *декомпозицию сети по числу выходных нейронов*. То есть вместо нейронной сети с 5 входами и 3 выходами создать 3 нейросети с 5 входами и 1 выходом. Такой прием 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, и структуру каждой такой нейронной сети необходимо оптимизировать отдельно с учетом обеспечения минимизации ошибки именно для нее.

Расчетное исследование

Рассмотрим опыт применения многослойного персептрона на примерах построения для центробежного компрессора моделей потерь в его безлопаточном диффузоре (БЛД) и энергетических характеристик промежуточной ступени.

Нейросетевые модели условного коэффициента трения $\lambda_{\text{усл}}$ и коэффициента потерь ζ в БЛД созданы на основе выборки из 308 векторов значений. При этом были проанализированы модули весовых коэффициентов для каждого входного аргумента (см. табл.).

У всех сформированных зависимостей наибольшее значение весового коэффициента – для параметра b_2/D_2 . Таким образом, на величину коэффициента потерь и условного коэффициента трения наибольшее влияние оказывает относительная ширина БЛД – b_2/D_2 .

Средние значения весов в моделях потерь в БЛД
Average values of weights in loss-efficiency model of the vaneless diffuser

Обобщенные виды анализируемых моделей БЛД	Среднее значение весов по всем четырем нейронам для параметра			
	Re _{c2} – число Рейнольдса	M _{c2} – число Маха	b ₂ /D ₂ – относительная ширина БЛД	α ₂ – угол потока на входе
$\lambda = f\left(\alpha_2, \frac{b_2}{D_2}, M_{c2}\right)$	–	4,62	4,99	3,66
$\lambda = f\left(\alpha_2, \frac{b_2}{D_2}, M_{c2}, Re_{c2}\right)$	2,57	2,08	3,39	2,22
$\zeta = f\left(\alpha_2, \frac{b_2}{D_2}, M_{c2}\right)$	–	2,99	5,39	2,13
$\zeta = f\left(\alpha_2, \frac{b_2}{D_2}, M_{c2}, Re_{c2}\right)$	2,27	1,97	4,17	1,44

Модели энергетических характеристик ступени компрессора строились на основе данных испытаний модельных ступеней, лицензия на которые была приобретена у компании «Dresser&Clark», а также на результатах экспериментальных исследований различных промежуточных ступеней центробежного компрессора, выполненных на кафедре компрессоростроения Ленинградского политехнического института и на Невском машиностроительном заводе. Исходная выборка составила 567 векторов по 32 параметра. Обобщенные зависимости политропного КПД и коэффициента напора имели вид $\eta = f(\Phi, M_u, G)$ и $\psi = f(\Phi, M_u, G)$, где Φ – условный коэффициент расхода, M_u – условное число Маха, G – совокупность параметров, описывающих геометрию проточной части ступени. Для нейросетевых моделей политропного КПД и коэффициента напора также был проведен анализ весовых коэффициентов.

Анализ представленных данных показывает, что все включенные в модель параметры имеют приблизительно одинаковый вес; в полученной модели политропного КПД ступени сравнительно меньший вес имеет и, соответственно, меньше влияет на КПД параметр b_4/D_2 , а на коэффициент напора меньше всего влияет параметр D_1/D_2 . Несмотря на некоторые различия, все весовые коэффициенты близки по величине. Поэтому по результатам анализа весовых коэффициентов для энергетических характеристик центробежного компрессора и потерь в БЛД все выбранные для моделирования параметры можно признать значимыми.

Средние значения весов для нейронных сетей, моделирующих энергетические характеристики ступени компрессора:

<i>Для политропного КПД</i>	<i>Для коэффициента напора</i>
<i>b₄</i> 0,38	<i>D₁</i> 0,36
<i>z_{ОНА}</i> 0,42	<i>D_{УП}</i> 0,42
<i>δ_{ОНА}</i> 0,43	<i>R₄</i> 0,42
<i>sm</i> 0,43	<i>b₁</i> 0,43
<i>D₀</i> 0,43	<i>l_{ОНА}</i> 0,44
<i>M_u</i> 0,43	<i>D₄</i> 0,44
<i>δ_{РК}</i> 0,44	<i>R_{S1}</i> 0,44
<i>b₁</i> 0,45	<i>D₅</i> 0,45
<i>b₆</i> 0,45	<i>R₃</i> 0,45
<i>β_{Л2}</i> 0,45	<i>D_{ВТ}</i> 0,46
<i>D₀₀</i> 0,46	<i>b₂</i> 0,46
<i>β_{Л1}</i> 0,46	<i>b₃</i> 0,46
<i>R₄</i> 0,46	<i>δ_{ОНА}</i> 0,47
<i>l_{ОНА}</i> 0,47	<i>M_u</i> 0,48
<i>D_{УП}</i> 0,47	<i>D₆</i> 0,48
<i>z_{РК}</i> 0,48	<i>β_{Л2}</i> 0,49
<i>R_{S2}</i> 0,48	<i>β_{Л1}</i> 0,49
<i>D_{ВТ}</i> 0,49	<i>D₂</i> 0,49
<i>b₂</i> 0,50	<i>b₆</i> 0,49
<i>β_{Л5}</i> 0,50	<i>z_{ОНА}</i> 0,50
<i>b₃</i> 0,51	<i>R_{S2}</i> 0,51
<i>R_{S1}</i> 0,51	<i>D₀</i> 0,51
<i>D₄</i> 0,51	<i>l_{РК}</i> 0,51
<i>l_{РК}</i> 0,52	<i>B₄</i> 0,51
<i>D₃</i> 0,52	<i>δ_{РК}</i> 0,52
<i>R₃</i> 0,54	<i>β_{Л5}</i> 0,52
<i>Φ</i> 0,55	<i>D₀₀</i> 0,53
<i>b₅</i> 0,55	<i>b₅</i> 0,55
<i>D₁</i> 0,55	<i>D₃</i> 0,55
<i>D₅</i> 0,56	<i>z_{РК}</i> 0,56
<i>D₆</i> 0,56	<i>Φ</i> 0,64
<i>ψ</i> 0,78	<i>η</i> 0,64

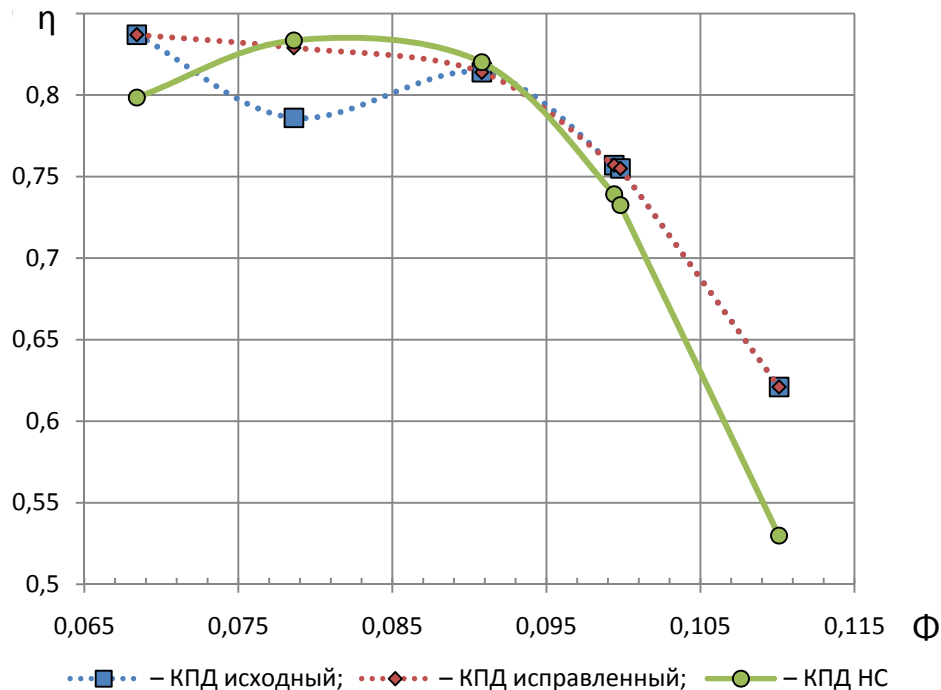


Рис. 1. Зависимости КПД от условного коэффициента расхода Φ для данных, содержащих выбросы, исправленных данных и смоделированных с помощью нейронных сетей

Fig. 1. Performances of polytropic efficiency of the compressor stage Φ for deviations data, corrected data and data simulated with neural network

Обучающая выборка исходных данных для нейросетевого моделирования энергетических характеристик и принятые при построении моделей обозначения параметров ступени подробно описаны в работах [10–12].

При предварительном визуальном изучении экспериментальных характеристик КПД ступеней центробежного компрессора был выявлен ряд значений, являющихся явными выбросами. Пример такой характеристики с выбросом одного значения приведен на рис. 1. На рисунке приняты следующие обозначения: КПД исходный – это значения, которые были представлены в исходной выборке; КПД исправленный – это те значения, которые вошли в обучающую выборку для нейронной сети; КПД НС – значения, которые рассчитывает обученная нейронная сеть. КПД исходный и исправленный совпадают для всех значений, кроме $\Phi = 0,0786$.

Обучение сети на предварительно не обработанном наборе данных может давать иска-

женные результаты, так как при подаче на разные входы сети данных различной размерности значения большего порядка (например, десятки и тысячи) будут оказывать большее влияние на выход сети. После нормировки размерности всех входных данных значения сводятся к одному порядку. Это позволяет улучшить обучение сети.

Проверка влияния нормировки проведена путем сравнения созданной ранее нейронной сети, обученной на ненормированных данных, и новой нейросети, обученной уже на нормированных данных.

Некоторые значения параметров (число лопаток рабочего колеса и обратного направляющего аппарата, углы входа и выхода лопаток рабочего колеса, углы выхода лопаток обратного направляющего аппарата) по модулю находились в диапазоне от 0 до 100. Остальные параметры меняли свои значения в диапазоне от 0 до 1. После нормирования данных на все

входы и выходы нейронной сети подаются значения от нуля до единицы.

Сравним результаты обучения нейронной сети для моделирования значения КПД на нормированной и ненормированной выборках. Обе модели представляли собой двухслойную нейронную сеть, реализующую зависимость вида $f(\Phi, M_u, G)$, где Φ – условный коэффициента расхода, M_u – число Маха, G – совокупность параметров, описывающих геометрию проточной части.

Средняя ошибка *ненормированной* обучающей выборки для расчетных значений политропного КПД $\eta = f(\Phi, M_u, G)$ составила 3,6 %.

Если не учитывать крайние по расходу точки, то среднее отклонение расчетных значений КПД на оптимальных режимах составляет 2,15 %.

Для *нормированных* данных средняя ошибка для расчетных значений политропного КПД $\eta = f(\Phi, M_u, G)$ составила 2,8 %. Если не учитывать точки с максимальными значениями расхода, то среднее отклонение расчетных значений КПД от экспериментальных составляет 1,2 %.

В качестве иллюстрации влияния нормирования параметров на рис. 2 приведены графики для двух различных ступеней центробежного компрессора.




Рис. 2. Зависимость КПД от условного коэффициента расхода:
 а – для ступени 2004, $D_2 = 0,352$ м; б – для ступени 3022, $D_2 = 0,419$ м

Fig. 2. Performances of politropic efficiency of the compressor stage for experimental data, simulated with neural network data and simulated after normalization data



Погрешности этих моделей имеют наибольшие значения в крайних точках области расходов. Как правило, эти зоны характеристик не используются при эксплуатации компрессорного оборудования. В рабочей зоне ступени компрессора модели на основе нейронных сетей аппроксимируют введенные данные с высокой точностью. Можно отметить, что при нормировании данных нейронная сеть точнее отслеживает форму зависимости и данные испытаний при минимальных расходах.

Обсуждение результатов

Приведенные результаты моделирования энергетических характеристик центробежных компрессоров и потерь в БДД наглядно показывают преимущества предварительной обработки обучающих данных. Это согласуется с результатами, которые получены зарубежными коллегами [22–24]. Предобработка выборки для обучения нейронной сети практически значима, так как позволяет существенно снизить погрешности моделирования по сравнению с нейронными сетями, созданными на неподготовленных исходных данных.

Заключение

В статье обобщен накопленный опыт предварительной обработки экспериментальных данных для обучения нейронных сетей при построении математических моделей энергетических характеристик центробежных компрессоров и сформулированы рекомендации по повышению точности нейросетевого моделирования в форме единого алгоритма, состоящего из последовательности этапов обработки исходной выборки. Предложенный алгоритм апробирован при моделировании энергетических характеристик промежуточной ступени центробежного компрессора и её элементов. Полученные результаты моделирования и существенное уменьшение погрешностей нейросетевых моделей показывают важность и необходимость предварительной обработки обучающей выборки. Например, использование нормирования данных позволило снизить погрешность моделирования политропного КПД на 1,5 % по сравнению с моделью, обученной на ненормированных данных.

СПИСОК ЛИТЕРАТУРЫ

1. Селезнев К.П., Галеркин Ю.Б. Центробежные компрессоры. Л.: Машиностроение, 1982. 271 с.
2. Галеркин Ю.Б., Рекстин А.Ф., Солдатова К.В., Дроздов А.А. Верификация новых версий Метода универсального моделирования центробежных компрессоров по результатам экспериментов // Компрессорная техника и пневматика. 2015. № 4. С. 21–31.
3. Галеркин Ю.Б. Турбокомпрессоры. М.: Изд-во КХТ, 2010.
4. Селезнев К.П., Подобуев Ю.С., Анисимов С.А. Теория и расчет турбокомпрессоров. Л.: Машиностроение. Ленингр. отд-ние, 1968. 408 с.: ил.
5. Лунев А.Т., Муртазин Р.Ф., Дроздов Ю.В., Хуснутдинов И.Ф. Исследование высокорасходных пространственных рабочих колес для современных центробежных компрессоров // Компрессорная техника и пневматика. 2017. № 6. С. 9–11.
6. Ахметзянов А.М., Лунев А.Т., Пашинкин Д.В. Центробежные компрессорные установки на базе современных высокорасходных ступеней с повышенным втулочным отношением рабочих колес // Газотурбинные технологии. 2015. № 7 (134). С. 6–7.
7. Japikse D. Design system development for turbomachinery (turbopump) designs – 1998 and a decade beyond // JANNAF Conference. Cleveland, Ohio: July 15–17. 1998.
8. <http://www.pcaeng.co.uk/software> [Электронный ресурс] / PCA EngineersLimited.
9. <https://www.pcaeng.co.uk/apps> [Электронный ресурс] / PCA EngineersLimited.
10. Никифоров А.Г., Попова Д.Ю., Солдатова К.В., Соловьева О.А. Использование нейросетевого моделирования для расчета энергетических характеристик центробежного компрессора // Компрессорная техника и пневматика. 2015. № 3. С. 18–21.

11. Никифоров А.Г., Попова Д.Ю., Солдатова К.В., Соловьева О.А. Опыт обобщения результатов расчетного исследования безлопаточных диффузоров центробежных компрессорных ступеней с помощью нейронно-сетевой модели // Компрессорная техника и пневматика. 2015. № 4. С. 14–16.

12. Никифоров А.Г., Попова Д.Ю., Солдатова К.В. Нейросетевые модели политропного КПД и коэффициента напора промежуточной ступени центробежного компрессора // Компрессорная техника и пневматика. 2015. № 6. С. 30–33.

13. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.

14. Казанцев П.А. Разработка и исследование маршрута проектирования нейросетевого приложения с аппаратной поддержкой: Дис. ... канд. техн. наук (05.13.01) / Казанцев Павел Александрович; МФТИ. М., 2008. 117 с.

15. Дагаева М.В., Сулейманов М.А., Катасёва Д.В., Катасёв 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.

16. Шкодырев В.П., Ягафаров К.И., Башговенко В.А., Ильина Е.Э. Обзор методов обнаружения аномалий в потоках данных // Proc. of the Second Conference on Software Engineering and Information Management. Санкт-Петербург, Россия. 2017. Vol. 1864. 7 с.

17. Осовский С. Нейронные сети для обработки информации/ Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 2002. 344 с.: ил.

18. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Изд-во Физико-математической литературы, 2001. 224 с.

19. Борисов В.В., Круглов В.В., Федулов А.С. Нечеткие модели и сети. 2-е изд., стереотип. М.: Горячая линия – Телеком, 2016. 284 с.: ил.

20. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6 / Под общ. ред. В.Г. Потемкина. М.: ДИАЛОГ-МИФИ, 2002. 496 с. (Пакеты прикладных программ; Кн. 4).

21. Борисов В.В., Федулов А.С., Зернов М.М. Основы гибридизации нечетких моделей. М.: Горячая линия – Телеком, 2017. 100 с.: ил.

22. Jayalakshmi T., Santhakumaran Dr.A. Statistical Normalization and Back Propagation for Classification // International Journal of Computer Theory and Engineering. 2011. Vol. 3. No 1. P. 89–93.

23. Ogasawara E.S., 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 // The 2010 International Joint Conference on Neural Networks (IJCNN). July 2010. DOI: 10.1109/IJCNN.2010.5596746

24. 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. P. 257–269.

СВЕДЕНИЯ ОБ АВТОРАХ

НИКИФОРОВ Александр Георгиевич – доктор технических наук заведующий кафедрой Смоленской сельскохозяйственной академии

E-mail: nikiforof@mail.ru

АВРАМЕНКО Дарья Юрьевна – аспирант Смоленского филиала ФГБОУ ВО НИУ «МЭИ»

E-mail: Leyzi-small@yandex.ru

Дата поступления статьи в редакцию: 25.09.2018

REFERENCES

[1] Seleznev K.P., Galerkin Yu.B. Tsentrobezhnyye kompressory. L.: Mashinostroyeniye, 1982. 271 s.: il. (rus.)

[2] Galerkin Yu.B., Rekestin A.F., Soldatova K.V., Drozdov, A.A. Verifikatsiya novykh versiy Metoda universal'nogo modelirovaniya tsentrobezhnykh kompressorov po rezultatam eksperimentov. *Kompressornaya tekhnika i pnevmatika*. 2015. № 4. S. 21–31. (rus.)

[3] Galerkin, Yu.B. Turbokompressory. M.: Izd-vo KKhT, 2010. (rus.)

[4] Seleznev K.P., Podobuyev Yu.S., Anisimov S.A. Teoriya i raschet turbokompressorov. L.: Mashinostroyeniye. Leningr. otd-niye, 1968. 408 s.: il. (rus.)

[5] Lunev A.T., Murtazin R.F., Drozdov Yu.V., Khusnutdinov I.F. Issledovaniye vysokoraskhodnykh



prostranstvennykh rabochikh koles dlya sovremennykh tsentrobezhnykh kompressorov. *Kompressornaya tekhnika i pnevmatika*. 2017. № 6. S. 9–11. (rus.)

[6] **Akhmetzyanov A.M., Lunev A.T., Pashinkin D.V.** Tsentrobezhnyye kompressornyye ustanovki na baze sovremennykh vysokoraskhodnykh stupeney s povyshennym vtulochnym otnosheniyem rabochikh koles. *Gazoturbinnyye tekhnologii*. 2015. № 7 (134). S. 6–7.

[7] **Japikse D.** Design system development for turbomachinery (turbopump) designs – 1998 and a decade beyond. *JANNAF Conference*. Cleveland, Ohio: July 15–17. 1998.

[8] <http://www.pcaeng.co.uk/software> [Elektronnyy resurs] / PCA Engineers Limited.

[9] <https://www.pcaeng.co.uk/apps> [Elektronnyy resurs] / PCA Engineers Limited.

[10] **Nikiforov A.G., Popova D.Yu., Soldatova K.V., Solovyeva O.A.** Ispolzovaniye neyrosetevogo modelirovaniya dlya rascheta energeticheskikh kharakteristik tsentrobezhnogo kompressora. *Kompressornaya tekhnika i pnevmatika*. 2015. № 3. S. 18–21. (rus.)

[11] **Nikiforov A.G., Popova D.Yu., Soldatova K.V., Solovyeva O.A.** Opyt obobshcheniya rezultatov raschetnogo issledovaniya bezlopatochnykh diffuzorov tsentrobezhnykh kompressornykh stupeney s pomoshchyu neyronno-setevoy modeli. *Kompressornaya tekhnika i pnevmatika*. 2015. № 4. S. 14–16. (rus.)

[12] **Nikiforov A.G., Popova D.Yu., Soldatova K.V.** Neyrosetevyye modeli politropnogo KPD i koeffitsiyenta napora promezhutochnoy stupeni tsentrobezhnogo kompressora. *Kompressornaya tekhnika i pnevmatika*. 2015. № 6. S. 30–33. (rus.)

[13] **Yasnitskiy L.N.** Intellektualnyye sistemy. M.: Laboratoriya znaniy, 2016. 221 s. (rus.)

[14] **Kazantsev P.A.** Razrabotka i issledovaniye marshruta proyektirovaniya neyrosetevogo prilozheniya s apparatnoy podderzhkoy: Dis. ... kand. tekhn. nauk (05.13.01) / Kazantsev Pavel Aleksandrovich; MFTI. M., 2008. 117 s. (rus.)

[15] **Dagayeva M.V., Suleymanov M.A., Kataseva D.V., Katasev A.S., Kirpichnikov A.P.** Tekhnologiya postroye-

niya otkazoustoychivyykh neyrosetevyykh modeley raspознаvaniya rukopisnykh simvolov v sistemakh biome-tricheskoy autentifikatsii. *Vestnik Tekhnologicheskogo universiteta*. 2018. T. 21. № 2. S. 133–138. (rus.)

[16] **Shkodyrev V.P., Yagafarov K.I., Bashtovenko V.A., Iliina Ye.E.** Obzor metodov obnaruzheniya anomalii v potokakh dannykh. *Proc. of the Second Conference on Software Engineering and Information Management*. Sankt-Peterburg, Rossiya. 2017. Vol. 1864. 7 c. (rus.)

[17] **Osovskiy S.** Neyronnyye seti dlya obrabotki informatsii / Per. s polskogo I.D. Rudinskogo. M.: Finansy i statistika, 2002. 344 s.: il. (rus.)

[18] **Kruglov V.V., Dli M.I., Golunov R.Yu.** Netchetkaya logika i iskusstvennyye neyronnyye seti. M.: Izd-vo Fiziko-matematicheskoy literatury, 2001. 224 s. (rus.)

[19] **Borisov V.V., Kruglov V.V., Fedulov A.S.** Netchetkiye modeli i seti. 2-ye izd., stereotip. M.: Goryachaya liniya – Telekom, 2016. 284 s.: il. (rus.)

[20] **Medvedev V.S., Potemkin V.G.** Neyronnyye seti. MATLAB 6/ Pod obshch. red. V.G. Potemkina. M.: DIALOG-MIFI, 2002. 496 s. (Pakety prikladnykh programm; Kn.4). (rus.)

[21] **Borisov V.V., Fedulov A.S., Zernov M.M.** Osnovy gibridizatsii nechetkikh modeley. M.: Goryachaya liniya – Telekom, 2017. 100 s.: il. (rus.)

[22] **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.

[23] **Ogasawara E.S., 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. *The 2010 International Joint Conference on Neural Networks (IJCNN)*. July 2010. DOI: 10.1109/IJCNN.2010.5596746

[24] **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. P. 257–269.

THE AUTHORS

NIKIFOROV Aleksandr G. – Smolensk agricultural academy

E-mail: nikiforof@mail.ru

AVRAMENKO Dariia Yu. – The Smolensk branch of the Moscow Power engineering institute

E-mail: Leyzi-small@yandex.ru

Received: 25.09.2018