

Аппроксимация нелинейной зависимости механической характеристики электродвигателя с помощью нейросетевого метода

М. Д. Закирова, А. П. Корчагин, Т. В. Лазовская, Д. А. Лавыгин, В. В. Паламарчук,
О. А. Скрипкин, Д. А. Тархов*, Д. А. Чернуха

ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого», г. Санкт-Петербург, Российская Федерация

Адрес: 195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29

* dtarkhov@gmail.com

Аннотация

Введение. В последние годы с помощью искусственных нейронных сетей решено много прикладных задач разной направленности. Нейронные сети могут использоваться для моделирования поведения физических систем, прогнозирования динамики процессов, анализа экспериментальных данных и оптимизации физических процессов. Применение нейронных сетей может быть полезно для моделирования различных явлений, начиная от простых физических моделей до сложных нелинейных систем, описывающих, например, поведение составного механизма.

Материалы и методы. В данной работе эффективность нейросетевого подхода демонстрируется для модели асинхронного электродвигателя АИР56А2. Двигатели данного типа хорошо совместимы с насосным оборудованием, используемом в сложной механической структуре таких сооружений, как гидроприводы разводных мостов. С помощью нейронной сети была аппроксимирована механическая характеристика двигателя, представляющая собой зависимость развиваемого момента от скорости вращения. Полученные результаты сравниваются с приближением данной зависимости с помощью параболы, построенной с применением классического статистического метода наименьших квадратов. Далее полученные аппроксимации используются в численном решении методом Эйлера для нелинейного дифференциального уравнения, описывающего динамику двигателя, а результаты в последствии оцениваются с помощью заранее заданного значения установившейся угловой скорости для данного двигателя.

Результаты исследования. Численные эксперименты демонстрируют достижение существенной разницы в результатах при применении многослойного персептрона к такой задаче по сравнению с классическим подходом.

Обсуждение и заключение. В связи с тем, что нейронная сеть аппроксимирует механическую характеристику существенно более точно, нейросетевой подход позволяет получить более точные результаты математического моделирования самого двигателя.

Ключевые слова: механическая характеристика двигателя, асинхронный двигатель, аппроксимация методом наименьших квадратов, метод Эйлера, наилучшие линейные несмещенные оценки, условия Гаусса-Маркова, многослойный персептрон, многослойная нейронная сеть, функция активации, функция потерь

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Для цитирования: Аппроксимация нелинейной зависимости механической характеристики электродвигателя с помощью нейросетевого метода / М. Д. Закирова [и др.] // Современные информационные технологии и ИТ-образование. 2024. Т. 20, № 2. С. 467-476. <https://doi.org/10.25559/SITITO.020.202402.467-476>

© Закирова М. Д., Корчагин А. П., Лазовская Т. В., Лавыгин Д. А.,
Паламарчук В. В., Скрипкин О. А., Тархов Д. А., Чернуха Д. А., 2024



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.



Approximation of the Nonlinear Dependence of the Mechanical Characteristics of an Electric Motor Using a Neural Network Method

M. D. Zakirova, A. P. Korchagin, T. V. Lazovskaya, D. A. Lavygin, V. V. Palamarchuk, O. A. Skripkin, D. A. Tarkhov*, D. A. Chernukha

Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, Russian Federation

Address: 29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation

* dtarkhov@gmail.com

Abstract

Introduction. In recent years, artificial neural networks have been used to solve a wide range of practical tasks. Neural networks can be utilized for modeling the behavior of physical systems, forecasting process dynamics, analyzing experimental data, and optimizing physical processes. The application of neural networks can be beneficial for modeling various phenomena, ranging from simple physical models to complex nonlinear systems, describing, for example, the behavior of composite mechanisms.

Materials and Methods. This study demonstrates the effectiveness of a neural network approach for modeling the asynchronous motor AIR56A2. Motors of this type are well-suited for compatibility with pump equipment used in the intricate mechanical structures of facilities such as drawbridge hydraulic drives. The neural network was employed to approximate the mechanical characteristics of the motor, representing the relationship between the developed torque and rotational speed. The obtained results are compared with the approximation of this relationship using a parabola, constructed using the classical statistical method of least squares. Subsequently, the obtained approximations are employed in the numerical solution using the Euler method for the nonlinear differential equation describing the engine's dynamics. The results are then assessed against a predefined value of the steady-state angular velocity for this motor.

Results. Numerical experiments demonstrate a significant difference in outcomes when applying a multilayer perceptron to such a task compared to the classical approach.

Discussion and Conclusion. Because the neural network approximates the mechanical characteristics much more accurately, the neural network approach enables more precise results in the mathematical modeling of the motor itself.

Keywords: Mechanical engine characteristics, asynchronous motor, least squares approximation, Euler's method, best linear unbiased estimate, Gauss-Markov conditions, multilayer perceptron, multilayer neural network, activation function, loss function

Conflict of interests: The authors declares no conflict of interest.

For citation: Zakirova M.D., Korchagin A.P., Lazovskaya T.V., Lavygin D.A., Palamarchuk V.V., Skripkin O.A., Tarkhov D.A., Chernukha D.A. Approximation of the Nonlinear Dependence of the Mechanical Characteristics of an Electric Motor Using a Neural Network Method. *Modern Information Technologies and IT-Education*. 2024;20(2):467-476. <https://doi.org/10.25559/SITITO.020.202402.467-476>



Введение

Процесс моделирования реальных объектов в классическом случае можно описать в два этапа: построение дифференциальной модели с граничными и начальными условиями и её исследование с помощью классических численных методов, таких как метод конечных объемов для задач гидрогазодинамики или метод конечных элементов для задач упругости. Полученные численные данные могут быть сравнены с экспериментальными данными реальных наблюдений или измерений. В случае, когда данные модели имеют значительные различия с экспериментальными данными, модель уточняется на уровне дифференциальных уравнений. Численные методы становятся более время затратными с повышением требований на точность решения. В ситуации же, когда результаты, полученные с помощью выбранных дифференциальных соотношений, отражающих суть физического процесса по мнению исследователя, не сходятся с экспериментальными данными, рассматривается построение модели на основе экспериментальных данных. С решением такой задачи хорошо справляются нейронные сети, что отражено во многих работах [1, 2]. Подобная реализация позволяет изучить работу объекта при варьировании значений различных параметров. Построение параметрических моделей физических и инженерных объектов с помощью нейросети, основанной на физических принципах объекта, предполагает более точные и эффективные решения. Исследования подобных подходов актуальны и приведены в ряде работ [3-6].

В данной работе рассматривается использование многослойной нейросетевой модели типа персептрон для аппроксимации механической характеристики трехфазного асинхронного электродвигателя. Это прибор, который широко применяется в практике в различных отраслях, таких как промышленное производство, транспорт, энергетика, строительство и бытовые устройства. Механическая характеристика¹ представляет собой зависимость между механическим параметром двигателя – крутящим моментом – и условиями его работы – частотой вращения вала двигателя. С помощью данной зависимости оценивается способность двигателя развивать определенный момент силы и поддерживать определенную скорость вращения в зависимости от нагрузки и часто определяется экспериментально. Использование нейросетевых аппроксимаций применительно к инженерным задачам является одной из передовых тематик, отвечающих концепции Industry 4.0 [7-11]. Индустрия 4.0 представляет собой новое направление развития производства, которое характеризуется использованием передовых технологий, таких как Интернет вещей (IoT), цифровое производство, облачные вычисления, искусственный интеллект (AI) и машинное обучение [12, 13]. Одним из ключевых направлений развития в рамках Индустрии 4.0 является применение нейронных сетей и других методов глубокого обучения для улучшения производственных процессов.

Цель исследования

Особую важность в современных инженерных реалиях представляет применение методов, способных предоставить более точ-

ную оценку функциональных взаимосвязей между физическими величинами. Эти методы могут включать в себя применение высокоточных численных алгоритмов, статистических моделей, а также передовых технологий в области искусственного интеллекта, таких как нейронные сети и глубокое обучение. Данные решения особенно актуальны в различных областях науки и техники, где часто присутствуют сложные и нелинейные взаимосвязи, такие как физика, биология, финансы, а также в области промышленности и инженерии. Применение нейросетевой аппроксимации может значительно улучшить точность моделирования и прогнозирования, что способствует более глубокому пониманию систем и развитию новых технологий.

Материалы и методы

1. Постановка задачи

Решается дифференциальное уравнение динамики электродвигателя

$$J\dot{\omega} = M_o - (M_n + M_y) \quad (1)$$

Задача включает в себя аппроксимацию механической характеристики двигателя. Механической характеристикой электродвигателя называется зависимость его частоты вращения n от развиваемого им момента M , то есть $n = f(M)$, описанной в работе. Обычно для её аппроксимации выбирается парабола с неизвестными коэффициентами:

$$M_o = a\omega^2 + b\omega + c, \quad \omega_1 < \omega < \omega_2. \quad (2)$$

Мы будем сравнивать эту аппроксимацию с нейросетевой. Уравнение (1) описывает, например, динамику гидропривода разводного моста [14]. В данной задаче суммарный момент приложенных к двигателю сопротивлений будет состоять из M_n, M_y – крутящих моментов на валах насоса и насоса управления.

где J – приведенный момент инерции вращающихся масс электродвигателя, муфты и насосов;

M_o – движущий крутящий момент электродвигателя;

M_n, M_y – крутящие моменты на валах насоса и насоса управления;

a, b, c – коэффициенты аппроксимации механической характеристики электродвигателя.

За начальные условия примем: при $t = 0$ $\omega = \omega_0$, где ω_0 – угловая скорость двигателя, принимаемая в качестве начального условия решения системы и равная минимальному значению устойчивой скорости при запуске.

В данной работе крутящие моменты на валах насоса и насоса управления принимаются за константы.

В качестве исследуемой модели двигателя был взят асинхронный электродвигатель модели АИР56А2. Данная модель часто встречается в большинстве систем автоматизации различных сфер промышленности, а также способна производить подъёмные работы и совместима с насосным оборудованием.

Электродвигатель оснащён статором, который создаёт магнитное поле с помощью медного эмалированного провода. Магнитное поле приводит во вращение ротор. Обмотки подсо-


¹ Автоматизированный электропривод с частотным управлением : учебное пособие / А. А. Евсиков, В. А. Коковин, А. П. Леонов. Дубна: Гос. ун-т «Дубна», 2020. 121 с. URL: https://www.uni-protvino.ru/images/publications/ump_atp/atp_em_14.pdf (дата обращения: 23.01.2024).



единены к источнику питания, который обеспечивает подачу электрического тока в систему.

Технические характеристики данной модели в дальнейшем будут использоваться для построения механической характеристики двигателя, которая будет аппроксимироваться классическим методом наименьших квадратов в виде параболы и нейронной сетью.

На рис. 1 изображен график механической характеристики, который описывает, как электродвигатель реагирует на различные нагрузки и как изменяется его выходная механическая характеристика в зависимости от условий работы², используемые далее значения приведены в таблице 1.



Р и с. 1. График механической характеристики электродвигателя модели АИР56А2

Fig. 1. Mechanical characteristics graph of the electric motor model АИР56А2

Источник: здесь и далее в статье все рисунки и таблицы составлены авторами.

Source: Hereinafter in the article, all tables and figures are compiled by the authors.

Т а б л и ц а 1. Таблица используемых значений для частоты вращения вала и крутящего момента

Table 1. Table of used values for shaft speed and torque

Частота вращения, об/мин	Крутящий момент, Нм
0	25
100	26
600	30
1200	35
1700	40
2050	45
2300	50
2400	55

² Деменков В. Расчет и построение механических характеристик асинхронного двигателя и двигателя постоянного тока [Электронный ресурс] // В Масштабе.ру, 2024. URL: <https://vmasshtabe.ru/electrooborudovanie/electric-motor/raschet-i-postroenie-mehanicheskikh-harakteristik-asinhronnogo-dvigatelya-i-dvigatelya-postoyannogo-toka.html> (дата обращения: 23.01.2024).

³ Линник Ю. В. Метод наименьших квадратов и основы математико-статистической теории обработки наблюдений. 2-е изд. М.: Физматгиз, 1962. (математическая теория). С. 275; Основы теории вероятности. Т. 2 Введение в математическую статистику / Б. Е. Аксенов, И. В. Афонькин, В. П. Евменов. М. И. Нечипоренко. Ленинград: Ленинградский политехнический институт, 1973. С. 98-100.


⁴ Магнус Я. Р. Эконометрика. Начальный курс: учебник / Я. Р. Магнус, П. К. Катышев, А. А. Пересецкий. М.: Изд. дом «Дело» РАНХиГС, 2021. 504 с. EDN: MDSVQL

⁵ Yan X., Su X. G. Linear Regression Analysis: Theory and Computing. World Scientific Publishing Co., Inc., USA, 2009. 348 p.

Частота вращения, об/мин	Крутящий момент, Нм
2500	60
2620	63
2770	55
2800	50
2850	45
2880	40
2890	35

2. Метод наименьших квадратов

Метод наименьших квадратов (МНК) является одним из наиболее распространенных и широко используемых методов статистической обработки данных³ [15]. Он может быть применен к большому количеству задач и моделей. В контексте модельной задачи МНК был использован для подбора коэффициентов параболы, которой аппроксимируется зависимость между крутящим моментом двигателя и скоростью вращения. Несмотря на то, что метод наименьших квадратов хорошо изучен и имеет множество модификаций (взвешенный метод наименьших квадратов, метод робастных наименьших квадратов и т. д.), у него есть ряд недостатков: чувствительность к случайным выбросам; метод имеет строгие требования, предъявляемые данным. Эти предположения отражены в условиях Гаусса-Маркова⁴ для получения наилучших (*Best Linear Unbiased Estimators, BLUE*) оценок параметров⁵. Также стоит учитывать, что принятая модельная зависимость может отличаться от реального поведения механического объекта, отражаемого в экспериментальных зависимостях, что приведет к получению неверных выводов о режимах работы объекта. На рис. 2 изображена аппроксимация механической характеристики электродвигателя параболой вида $U_1(\omega) = a\omega^2 + b\omega + c$, где коэффициенты находятся методом наименьших квадратов.




Р и с. 2. Аппроксимация с помощью МНК для полного набора точек

Fig. 2. Least Squares Approximation for a complete set of points



Как видно из графика на рис. 2, полную и достаточно точную информацию о механической характеристике двигателя на всем рассматриваемом участке с помощью описания параболы получить нельзя, однако такая аппроксимация применима при рассмотрении некоторого более узкого диапазона скоростей вращения двигателя, где данный метод дает более точные результаты. Данный результат представлен на рис. 3.



Р и с. 3. Аппроксимация с помощью МНК для начального участка
F i g. 3. Least Squares Approximation for the initial section


3. Многослойный персептрон

При классическом подходе к моделированию реальных объектов процесс можно разделить на два основных этапа. Вначале строится математическая модель в виде дифференциальных уравнений, которая описывает поведение объекта с учетом граничных и начальных условий, затем проводится исследование этой модели с использованием традиционных численных методов⁶. Однако для некоторых задач этот подход может быть недостаточным эффективным, и в таких случаях требуется применение более сложных и продвинутых методов. Эти более сложные методы могут включать в себя использование нейронных сетей⁷ для получения информации о поведении объекта и разработки модели на основе этих данных. Нейронные сети обладают способностью извлекать сложные закономерности из больших объемов данных и могут быть эффективно использованы для моделирования сложных систем, где классические методы могут не давать удовлетворительных результатов [16-18]. Такой подход, кроме того, приводит к лучшему пониманию поведения объекта и повышению точности моделирования в сложных и многофакторных системах.

В данном исследовании нами использовалась многослойная нейронная сеть вида персептрон (*Multilayer Perceptron*)⁸ [19-22]. Теоретической обоснованностью выбора данного вида нейронной сети является теорема А. Н. Колмогорова⁹, играющая важную роль в теории искусственного интеллекта и нейронных сетей, поскольку подтверждает способность многослой-

ных персептронов представлять широкий класс функций. Согласно теореме, персептрон является универсальной функцией для аппроксимации, то есть способен приближать любые функции при условии достаточного количества нейронов и правильного выбора функции активации.

Для нейронных сетей типа персептрон характерно наличие нескольких слоев нейронов: входного, выходного и скрытых слоев. Общая схема сети изображена на рис. 4.



Р и с. 4. Архитектура многослойного персептрона
F i g. 4. Multilayer Perceptron Architecture

В рассматриваемой нами постановке задачи для получения аппроксимации функции механической характеристики двигателя любой точности достаточно использовать нейронную сеть типа персептрон с одним скрытым слоем. Таким образом, нейронная сеть состоит из трех основных слоев [23, 24]. Первый слой, известный как входной слой, принимает представленные вектором признаков или активациями нейронов из предыдущего слоя, входные данные. Скрытые слои, находящиеся между входным и выходным слоями, отвечают за обработку информации и передачу ее на выходной слой. Архитектура сети определяет количество скрытых слоев и нейронов в каждом из них в зависимости от сложности модели и предполагаемых требований. Выходной слой выполняет задачу предсказания значений или классификации входных данных.

Процесс обучения включает в себя следующие этапы: в начале происходит инициализация начальных значений нейронов, и затем их параметры уточняются в ходе обучения. Целью изменения параметров является минимизация ошибки между выходными результатами сети и целевыми данными. Далее, на втором этапе, определяется функция потерь, которая в данном случае представляет собой сумму квадратов ошибок, после чего выполняются итеративные процессы обновления параметров (методом градиентного спуска), чтобы настроить

⁶ Вержбицкий В. М. Основы численных методов : учебник. Изд. 5-е. Москва ; Берлин : Директ-Медиа, 2021. 850 с. <https://doi.org/10.23681/601641>

⁷ Васильев А. Н., Тархов Д. А. Нейросетевое моделирование. Принципы. Алгоритмы. Приложения : монография. Санкт-Петербург: Изд-во Политехнического ун-та, 2009. 527 с. EDN: QMTVRJ

⁸ Гафаров Ф. М., Галимянов А. Ф. Искусственные нейронные сети и приложения : учеб. пособие. Казань: Изд-во Казан. ун-та, 2018. 121 с. [Электронный ресурс]. URL: https://kpfu.ru/staff_files/F1493580427/NejronGafGal.pdf (дата обращения: 23.01.2024).

⁹ Головкин, В. А. Нейроинтеллект: теория и применение : в 2 кн. Брест: БПИ, 1999. Кн. 1: Организация и обучение нейронных сетей с прямыми и обратными связями. 260 с. [Электронный ресурс]. URL: <https://rep.bstu.by/handle/data/30365> (дата обращения: 23.01.2024).




параметры так, чтобы функция потерь была сведена к минимуму как можно быстрее. По мере уменьшения значения функции потерь, происходит обновление параметров нейронов для наилучшего соответствия между выходными данными сети и ожидаемыми значениями [25].

К каждому нейрону после обработки входных сигналов применяется функция активации, в нашем случае это гиперболический тангенс, далее результаты передаются следующему слою нейронов. Таким образом, в качестве нейросетевой аппроксимации кривой $U(\omega)$ мы получим функцию вида


$$U_2(\omega) = \sum_{i=1}^n c_i \tanh(a_i(\omega - b_i)), \quad (3)$$

полученную в результате обучения нейронной сети типа персептрон с одним скрытым слоем.


Используемый программный код позволяет наблюдать за процессом обучения нейронной сети через графическую визуализацию результатов, представленных на рис. 5-7.



Р и с. 5. Результат аппроксимации на первом шаге обучения
F i g. 5. The approximation result at the first step of training



Р и с. 6. Результат аппроксимации на промежуточном шаге обучения
F i g. 6. The approximation result at the intermediate training step



Р и с. 7. Результат аппроксимации на последнем шаге обучения
F i g. 7. The approximation result at the last training step

На графиках (рис. 5-7) продемонстрирована работа алгоритма обратного распространения ошибки, целью которого является минимизация функции ошибки. На рис. 6 представлен промежуточный шаг обучения, который позволяет нам убедиться, что ошибка снизилась, а выход от модели с новыми весами стал ближе к ожидаемому. Итоговая функция аппроксимации (рис. 7) является более точной, нежели аппроксимация параболой.

4. Численное решение методом Эйлера

Поскольку основной вклад в общий момент дает движущий крутящий момент электродвигателя, примем $M = M_u + M_y = 10H \cdot M$, чтобы он был меньше, чем $M_o(0) = 25H \cdot M$. Момент инерции влияет на скорость разгона двигателя, что отвечает длительности переходного процесса, что в текущей задаче несущественно, пример $J = 1 \text{ кг} \cdot \text{м}^2$. Угловая скорость двигателя – ω_0 , принимаемая в качестве начального условия решения системы и равная минимальному значению устойчивой скорости при запуске. Для электродвигателя АИР56А2 это значение равно $\omega_0 = 0,9 \text{ об/мин}$. Для численного решения задачи Коши на промежутке $[0; \omega_{\max}]$ применима широкая палитра численных методов. Значительная часть из них заключается в делении данного промежутка точками t_k на интервалы длины $h_k = t_k - t_{k-1}$ и применении рекуррентной формулы

$$y_{k+1} = y_k + F(f, h_k, y_k, y_{k+1}), k = 1, 2, 3, \dots, n,$$

где оператор F определяет конкретный метод.

Для решения задачи о механической характеристике двигателя воспользуемся методом Эйлера

$$y_{k+1} = y_k + F(f, h_k, y_k, y_{k+1}), k = 1, 2, 3, \dots, n$$

$$y_{k+1} = y_k + h \cdot f(y_{k+1}), k = 1, 2, 3, \dots, n,$$

Основная задача – сравнить численное решение нелинейного дифференциального уравнения первого порядка при разных функциях аппроксимации механической характеристики электродвигателя.


Классическая физическая модель предлагает в качестве $U(\omega)$ использовать параболу $U_1(\omega) = a\omega^2 + b\omega + c$

где a, b, c – коэффициенты аппроксимации механической характеристики электродвигателя. Мы предлагаем вместо неё использовать персептрон (3).




Результаты исследования

На первом этапе исследования сравнивался участок функции механической характеристики двигателя, при котором крутящий момент возрастает с повышением частоты вращения (первые 10 точек). Результаты, полученные параболической аппроксимацией методом наименьших квадратов, изображенные на рис. 3, визуально менее точно описывают поведение исследуемой функциональной зависимости, нежели результаты, полученные с помощью многослойного персептрона и представленные на рис. 8.



Р и с. 8. Результаты, полученные для 10 точек с помощью нейронной сети
F i g. 8. Results obtained for 10 points using neural network

На рис. 9 продемонстрированы решения нелинейного дифференциального уравнения первого порядка (уравнение динамики двигателя) с нулевым начальным условием первого рода с помощью функций U_1 (парабола) и U_2 (нейронная сеть). Таким образом, при рассмотрении частоты вращения вала, соответствующей участку, где возрастание частоты сопровождается возрастанием момента, решения близки.




Р и с. 9. Решение уравнения динамики двигателя с нулевым начальным условием первого рода с правой частью вида параболы и нейронной сети
F i g. 9. Solution of the equation of engine dynamics with a zero initial condition of the first kind with the right-hand side of the form of a parabola and a neural network

На втором этапе была выполнена оценка полной механической характеристики двигателя. На рис. 10 продемонстрировано решение нелинейного дифференциального уравнения первого порядка (уравнение динамики двигателя) с нулевым начальным условием первого рода с помощью функций U_1 (па-

рабола) и U_2 (нейронная сеть) для полного интервала изменения частоты вращения (15 точек).

Аппроксимация с помощью МНК для полного набора точек оказалась недостаточно точной для достоверного воспроизведения экспериментальной зависимости (рис. 2). Однако результаты, полученные в результате применения многослойного персептрона, описанной выше, демонстрируют высокую степень точности (рис. 7).



Р и с. 10. Решение уравнения динамики двигателя с нулевым начальным условием первого рода с правой частью вида параболы и нейронной сети для полного интервала изменения частоты вращения (нижняя кривая для U_2 , верхняя кривая для U_1)

F i g. 10. Solution of the equation of engine dynamics with a zero initial condition of the first kind with the right-hand side in the form of a parabola and a neural network for the full range of rotation frequency change (lower curve for U_2 , upper curve for U_1)

Одной из характеристик двигателя АИР56А2 является рабочая (максимальная) частота вращения равная $\omega^* = 3000 \frac{\text{об}}{\text{мин}}$. Исходя из определения рабочей частоты вращения, мы можем предположить, что более точное решение выходит на данное значение частоты и далее остается неизменным. Очевидно, что только нейросетевая аппроксимация соответствует заявленным характеристикам двигателя и, следовательно, точнее описывает механический объект, представленный в виде дифференциальной модели.

Выводы

В данной работе продемонстрирована важность применения передовых технологий в области искусственного интеллекта применительно к задачам аппроксимации данных, полученных экспериментально, при изучении физического процесса в механической системе. Решена задача для определения функциональной зависимости между частотой вращения вала двигателя и развиваемого им момента, то есть механической характеристики двигателя. Подход, основанный на нейронной сети с правильно выбранной функцией активации, дает значительно более точные результаты для полного интервала изменения частоты вращения, нежели классический подход, состоящий в подборе аппроксимирующей функции в виде параболы. Однако стоит отметить, что классический подход применим и хорошо описывает поведение объекта на некотором более узком диапазоне частот.



References

- [1] Lazovskaya T., Malykhina G., Tarkhov D. Physics-based neural network methods for solving parameterized singular perturbation problem. *Computation*. 2021;9(9):97. <https://doi.org/10.3390/computation9090097>
- [2] Vasilyev A.N., Gorokhovskaya V.A., Korchagin A.P., Lazovskaya T.V., Tarkhov D.A., Chernukha D.A. Investigation of the Predictive Capabilities of a Data-Driven Multilayer Neuromorphic Model by the Example of the Duffing Oscillator. *Modern Information Technologies and IT-Education*. 2021;17(3):625-632. (In Russ., abstract in Eng.) <https://doi.org/10.25559/SITITO.17.202103.625-632>
- [3] Lazovskaya T., Malykhina G., Tarkhov D. Construction of an Individual Model of the Deflection of a PVC-Specimen Based on a Differential Equation and Measurement Data. In: Proceedings of the 2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon 2020). Vladivostok, Russia: IEEE Press; 2020. p. 9271144. <https://doi.org/10.1109/FarEastCon50210.2020.9271144>
- [4] Bolgov I., Kaverzneva T., Kolesova S., Lazovskaya T., Stolyarov O., Tarkhov D. Neural network model of rupture conditions for elastic material sample based on measurements at static loading under different strain rates. *Journal of Physics: Conference Series*. 2016;772:012032. <https://doi.org/10.1088/1742-6596/772/1/012032>
- [5] Filkin V., Kaverzneva T., Lazovskaya T., Lukinskiy E., Petrov A., Stolyarov O., Tarkhov D. Neural network modeling of conditions of destruction of wood plank based on measurements. *Journal of Physics: Conference Series*. 2016;772:012041. <https://doi.org/10.1088/1742-6596/772/1/012041>
- [6] Lazovskaya T.V., Tarkhov D.A., Vasilyev A.N. Parametric Neural Network Modeling in Engineering. *Recent Patents on Engineering*. 2017;11:10-15. <https://doi.org/10.2174/1872212111666161207155157>
- [7] Lee J., Bagheri B., Kao H.-A. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*. 2015;3:18-23. <https://doi.org/10.1016/j.mfglet.2014.12.001>
- [8] Babkin A.V., Shkarupeta E.V., Tashenova L.V. Methodology for assessing the convergence of digital industrialization and industrial digitalization in the conditions of Industry 4.0 and 5.0. *π-Economy*. 2023;16(5):91-108. (In Russ., abstract in Eng.) <https://doi.org/10.18721/JE.16507>
- [9] Jagtap A.D., Kawaguchi K., Karniadakis G.E. Adaptive activation functions accelerate convergence in deep and physics-informed neural networks. *Journal of Computational Physics*. 2020;404:109136. <https://doi.org/10.1016/j.jcp.2019.109136>
- [10] Zobeiry N., Humfeld K.D. A physics-informed machine learning approach for solving heat transfer equation in advanced manufacturing and engineering applications. *Engineering Applications of Artificial Intelligence*. 2021;101:104232. <https://doi.org/10.1016/j.engappai.2021.104232>
- [11] Huang G., Zhu Q., Siew C. Extreme learning machine: Theory and applications. *Neurocomputing*. 2006;70(1-3):489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- [12] Rasheed A., San O., Kvamsdal T. Digital Twin: Values, Challenges and Enablers From a Modeling Perspective. *IEEE Access*. 2020;8:21980-22012. <https://doi.org/10.1109/ACCESS.2020.2970143>
- [13] Rai R., Sahu C.K. Driven by Data or Derived Through Physics? A Review of Hybrid Physics Guided Machine Learning Techniques With Cyber-Physical System (CPS) Focus. *IEEE Access*. 2020;8:71050-71073. <https://doi.org/10.1109/ACCESS.2020.2987324>
- [14] Ashcheulov A.V. Controlling motion of metal bascule structures by fluid power system (exemplified by lifting of bascule bridge span). *IOP Conference Series: Materials Science and Engineering*. 2021;1103:012001. <https://doi.org/10.1088/1757-899X/1103/1/012001>
- [15] Belov A.G. A Mathematical-Statistics Approach to the Least Squares Method. *Computational Mathematics and Modeling*. 2018;29:30-41. <https://doi.org/10.1007/s10598-018-9385-6>
- [16] Kovalchuk S.V., Metsker O.G., Funkner A.A., Kisliakovskii I.O., Nikitin N.O., Kalyuzhnaya A.V., Vaganov D.A., Bochenina K.O. A Conceptual Approach to Complex Model Management with Generalized Modelling Patterns and Evolutionary Identification. *Complexity*. 2018;2018:5870987. <https://doi.org/10.1155/2018/5870987>
- [17] Kim S.W., Kim I., Lee J., Lee S. Knowledge Integration into deep learning in dynamical systems: An overview and taxonomy. *Journal of Mechanical Science and Technology*. 2021;35:1331-1342. <https://doi.org/10.1007/s12206-021-0342-5>
- [18] Zhang Z., Rai R., Chowdhury S., Doermann D. MIDPhyNet: Memorized infusion of decomposed physics in neural networks to model dynamic systems. *Neurocomputing*. 2021;428:116-129. <https://doi.org/10.1016/j.neucom.2020.11.042>
- [19] Lazovskaya T., Tarkhov D. Multilayer neural network models based on grid methods. *IOP Conference Series: Materials Science and Engineering*. 2016;158:012061. <https://doi.org/10.1088/1757-899X/158/1/012061>
- [20] Lazovskaya T., Tarkhov D. Fresh approaches to the construction of parameterized neural network solutions of a stiff differential equation. *St. Petersburg Polytechnical University Journal: Physics and Mathematics*. 2015;1(2):192-198. <https://doi.org/10.1016/j.spjpm.2015.07.005>
- [21] Boyarsky S., Lazovskaya T., Tarkhov D. Investigation of the Predictive Capabilities of a Data-Driven Multilayer Model by the Example of the Duffing Oscillator. In: Proceedings of the 2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon 2020). Vladivostok, Russia: IEEE Press; 2020. p. 1-5. <https://doi.org/10.1109/FarEastCon50210.2020.9271195>
- [22] Hornik K., Tinchcombe M., White H. Multilayer Feedforward Networks are Universal Approximators. *Neural Networks*. 1989;2(5):359-366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)



- [23] Ismailov V.E. Approximation by ridge functions and neural networks with a bounded number of neurons. *Applicable Analysis*. 2014;94(11):2245-2260. <https://doi.org/10.1080/00036811.2014.979809>
- [24] Huang G., Chen L., Siew C. Universal Approximation using Incremental Constructive Feedforward Networks with Random Hidden Nodes. *IEEE Transactions on Neural Networks*. 2006;17(4):879-892. <https://doi.org/10.1109/TNN.2006.875977>
- [25] Famelis I.T., Kaloutsas V. Parameterized neural network training for the solution of a class of stiff initial value systems. *Neural Computing and Applications*. 2021;33:3363-3370. <https://doi.org/10.1007/s00521-020-05201-1>

Поступила 23.01.2024; одобрена после рецензирования 11.03.2024; принята к публикации 16.05.2024.

Submitted 23.01.2024; approved after reviewing 11.03.2024; accepted for publication 16.05.2024.

Об авторах:

Закирова Мария Денисовна, студент Высшей школы механики и процессов управления, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0009-0009-7115-6719>, maria.za.04@mail.ru

Корчагин Александр Павлович, студент Высшей школы механики и процессов управления, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0000-0002-2201-306X>, alexandr.korchagin16@gmail.com

Лазовская Татьяна Валерьевна, старший преподаватель кафедры высшей математики Института физики и математики, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0000-0002-3324-6213>, tatianala@list.ru

Лавыгин Дмитрий Алексеевич, студент Высшей школы механики и процессов управления, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0009-0009-7474-3097>, lavygin.04@mail.ru

Паламарчук Вероника Вячеславовна, аспирант Высшей школы компьютерных технологий и информационных систем, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0009-0002-8560-0461>, nika.pal@mail.ru

Скрипкин Олег Алексеевич, студент Высшей школы механики и процессов управления, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0009-0004-6251-2607>, oleg.skri@gmail.com

Тархов Дмитрий Альбертович, профессор кафедры высшей математики Института физики и математики, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), доктор технических наук, доцент, ORCID: <https://orcid.org/0000-0002-9431-8241>, dtarkhov@gmail.com

Чернуха Дарья Антоновна, студент Высшей школы механики и процессов управления, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого» (195251, Российская Федерация, г. Санкт-Петербург, ул. Политехническая, д. 29), ORCID: <https://orcid.org/0000-0002-0374-8319>, chernukha_da@mail.ru

Все авторы прочитали и одобрили окончательный вариант рукописи.

About the authors:

Maria D. Zakirova, Student of the Higher School of Mechanics and Control Processes, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), ORCID: <https://orcid.org/0009-0009-7115-6719>, maria.za.04@mail.ru

Alexander P. Korchagin, Student of the Higher School of Mechanics and Control Processes, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), ORCID: <https://orcid.org/0000-0002-2201-306X>, alexandr.korchagin16@gmail.com

Tatyana V. Lazovskaya, Senior Lecturer of the Department of Higher Mathematics, Institute of Physics and Mathematics, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), ORCID: <https://orcid.org/0000-0002-3324-6213>, tatianala@list.ru

Dmitry A. Lavygin, Student of the Higher School of Mechanics and Control Processes, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), ORCID: <https://orcid.org/0009-0009-7474-3097>, lavygin.04@mail.ru

Veronica V. Palamarchuk, Postgraduate Student of the Higher School Computer Technology and Information Systems, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), ORCID: <https://orcid.org/0009-0002-8560-0461>, nika.pal@mail.ru

Oleg A. Skripkin, Student of the Higher School of Mechanics and Control Processes, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), ORCID: <https://orcid.org/0009-0004-6251-2607>, oleg.skri@gmail.com



Dmitry A. Tarkhov, Professor of the Department of Higher Mathematics, Institute of Physics and Mathematics, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), Dr. Sci. (Eng.), Associate Professor, **ORCID:** <https://orcid.org/0000-0002-9431-8241>, dtarkhov@gmail.com

Daria A. Chernukha, Student of the Higher School of Mechanics and Control Processes, Peter the Great St. Petersburg Polytechnic University (29 Polytechnicheskaya St., 195251 St. Petersburg, Russian Federation), **ORCID:** <https://orcid.org/0000-0002-0374-8319>, chernukha_da@mail.ru

All authors have read and approved the final manuscript.

