

УДК 621.311.001.57

ББК 31.27-05

О.Н. АНДРЕЕВ, В.В. АНДРЕЕВ,
Н.В. РУССОВА, А.Л. СЛАВУТСКИЙ**КОНТРОЛЬ НЕСТАЦИОНАРНЫХ СИГНАЛОВ
С МИНИМАЛЬНОЙ ЗАДЕРЖКОЙ:
НЕЙРОСЕТЕВАЯ РЕАЛИЗАЦИЯ**

Ключевые слова: нейронные сети, микропроцессорная реализация, нестационарные сигналы, временное окно.

В электротехнике и энергетике для анализа сигналов тока и напряжения широко применяются алгоритмы на основе преобразования Фурье. Это приводит к временной задержке в определении параметров, составляющей не менее периода сигнала промышленной частоты. Для ряда задач актуальным является определение параметров нестационарных сигналов с минимальной задержкой.

Цель исследования – показать возможность контроля параметров сигналов за временной интервал в доли периода промышленной частоты на основе микропроцессорной реализации нейросетевых алгоритмов.

Материалы и методы. Программно-аппаратные средства реализованы в стандартном для релейной защиты и автоматизации микропроцессорном оборудовании на основе простейших нейронных сетей прямого распространения. Экспериментальная проверка алгоритмов проводилась в лабораторных условиях на примере контроля сигналов тока в асинхронном двигателе при отключении и включении питания в течение одного периода промышленной частоты.

Результаты исследования. Показано, что предлагаемый подход позволяет фиксировать начало переходных процессов и скорость изменения частоты сигналов в течение временного окна длительностью единицы миллисекунд. При этом могут одновременно использоваться нейронные сети разной структуры. Время получения результатов вычислений обученной нейронной сетью соответствует режиму обработки сигналов в реальном времени.

Выводы. Обучение нейронных сетей проводится при помощи простых аналитических формул и может быть реализовано в широком диапазоне варьирования параметров сигналов. Для решения поставленных задач могут одновременно использоваться несколько простейших нейронных сетей, получаемые при этом результаты могут дополнять и уточнять друг друга.

Введение. Нейросетевые алгоритмы в последние годы широко используются для решения самых разных задач регрессии и классификации данных [17, 22, 25]. В электротехнике и электроэнергетике решаются оба класса задач: классификация неисправностей [15, 23, 26], контроль качества электроэнергии [29] и прогнозирования энергопотребления [6, 11, 13, 27], определение места повреждения [14, 16, 19, 30], фильтрация и шумоподавление сигналов [20, 28], идентификация параметров электротехнических систем [4, 9, 24], моделирование и «цифровые двойники» [12] и т.д.

В большинстве случаев нейросетевые алгоритмы используются в отложенном времени при анализе больших массивов данных. Обучение нейронных сетей [1, 18] проводится чаще всего на моделях в связи с тем, что на экспериментальных данных трудно создать необходимую выборку с варьированием всех параметров. Кроме того, нейронные сети прямого распространения (персептроны) после

обучения могут быть занесены в микропроцессорное оборудование и использоваться для контроля динамических процессов в реальном времени [8, 18].

Цель исследования – показать возможность контроля параметров сигналов за временной интервал в доли периода промышленной частоты на основе микропроцессорной реализации нейросетевых алгоритмов. Соответствующий подход продемонстрирован на примере контроля в реальном времени сигналов тока в асинхронном двигателе при включении/отключении питания.

Материалы и методы. Для контроля нестационарных параметров сигналов в скользящем временном окне при частоте дискретизации до 96 выборок на период промышленной частоты 50 Гц использовались алгоритмы на основе многослойного персептрона. Обученная искусственная нейронная сеть (ИНС) в виде таблицы весовых коэффициентов и коэффициентов смещения реализовывалась в микропроцессорном устройстве. ИНС предварительно обучались на персональном компьютере, а затем заносились в RISC-микроконтроллер (Reduced Instruction Set Computer) с тактовой частотой до 100 МГц. Замеры с помощью аппаратных средств самого микроконтроллера показали, что работа каждой ИНС занимает не более 100 мкс процессорного времени.

Для обучения персептронов написана программа на языке Python, позволяющая менять количество входных нейронов в соответствии с размером скользящего временного окна, количество нейронов в скрытых слоях, целевую функцию на выходе. Результаты обучения нейронной сети и её функционирование в режиме «если то» проверялись при помощи аналитической платформы Deductor, позволяющей реализовать нейросетевые алгоритмы. На рис. 1 для примера представлены гистограммы распределения ошибок при определении коэффициента усиления передаточного звена в скользящем временном окне [28].

Сравнение результатов, полученных при использовании написанной программы на Python, и результатов, полученных с помощью российской платформы Deductor, позволяет сделать вывод о хорошем соответствии средних и максимальных ошибок при обучении нейронной сети. Проверка скорости вычислений микропроцессорного устройства со встроенной нейронной сетью показала, что даже без специальной оптимизации вычислительных процессов время получения значений целевой функции в режиме «если то» составляет 50–80 мс. Это соответствует обработке сигналов в реальном времени (менее интервала между двумя последовательными отсчётами сигнала). Таким образом, задержка при обработке сигнала определяется размерами скользящего временного окна.

На рис. 2 представлена схема лабораторной установки для проверки реализованных алгоритмов контроля нестационарных сигналов.

Асинхронный двигатель включался через тиристорный регулятор, позволяющий отключать и включать питающее напряжение каждый период промышленной частоты с переменной регулируемой скважностью. Сигналы тока статора двигателя оцифровывались с частотой 4800 Гц и подавались в микропроцессорное устройство с реализованным в нём нейросетевым алгоритмом. В зависимости от решаемых задач размеры временного окна (количество входных нейронов), количество скрытых слоев и нейронов в них у ИНС могут меняться.


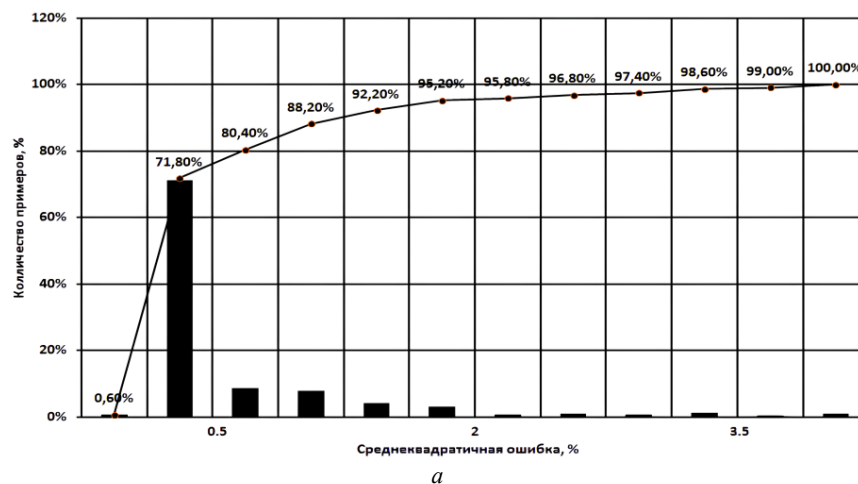


Рис. 1. Гистограммы распределения ошибок при обучении перцептрона на Python (а) и в Deductor (б)

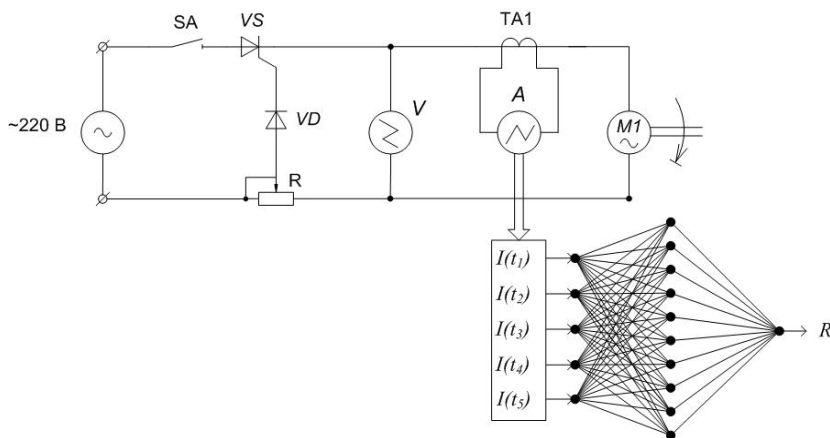


Рис. 2. Схема лабораторной установки для контроля сигналов тока в асинхронном двигателе

Результаты исследования. Приведем пример нейросетевой оценки изменения частоты тока при включении тиристора по схеме рис. 2. Эксперименты проводились при скважности (заполнении) 64%, 40%, 33% от периода сигнала промышленной частоты.

Сигнал тока при отсутствии регулирования аппроксимировался по следующей формуле:

$$I = I_1 \sin(2\pi ft + \varphi), \quad (1)$$

где амплитуда тока $I_1 = 265$ мА; частота $f = 50$ Гц; фаза $\varphi = 1,75$ рад.

Для аппроксимации сигнала $I_{\text{вкл}}$ в момент открытия тиристора и создания обучающей выборки использовалась формула

$$I_{\text{вкл}} = I_1 \sin(2\pi(f - \Delta f)t). \quad (2)$$

Предварительная проверка показала высокую точность аппроксимации тока по обеим формулам: максимальное отклонение экспериментальных записей не превышало 1%. При $f = 50$ Гц и обозначенных значениях скважности сигнала $\Delta f = 23\,700, 43\,000, 60\,000$ Гц/с соответственно.

Для обучения ИНС было подготовлено 4000 сигналов. 2000 сигналов моделировались по формуле (1) (нет разгона, установившийся режим), где I_1, φ – случайные величины, равномерно распределенные в соответствующих диапазонах I_1 – от 120 до 300 мА, φ – от 0 до 2π рад, а $f = 50$ Гц. Следующие 2000 сигналов моделировалось по формуле (2) (включение, разгон двигателя), где случайные величины распределены в следующих диапазонах: I_1 – от 120 до 300 мА, f – от 100 до 200 Гц, Δf – от 10 000 до 80 000 Гц/с, φ – 0 до 0,628 рад.

На вход ИНС подаются последовательные дискретные отсчеты сигнала тока $I(t)$. Частота дискретизации сигнала тока 4800 Гц (96 выборок на период сигнала промышленной частоты 50 Гц).

В качестве активационной функции выбрана сигмоида, крутизна которой – 1. Алгоритм обучения – Back propagation, скорость обучения – 0,1, момент – 0,9. Количество эпох ограничено 10000.

Во входном слое ИНС 5 нейронов, на которые подаются последовательные отсчёты сигнала тока. Временное окно соответствует 1,042 мс. Скрытый слой один с 10 нейронами. На выходе ИНС 1 нейрон – скорость изменения частоты $R = \Delta f$ (см. рис. 2).

Вторая ИНС, которая использовалась для анализа сигналов, отличалась от описанной только целевой функцией. Она решает задачу классификации: на ее выходе 1 нейрон – разгон есть ($R = 1$) либо разгона нет ($R = 0$).

На рис. 3 приведен пример нейросетевого контроля сигналов при включении электродвигателя через тиристорный регулятор. Заполнение ~64%, т.е. тиристор открывается при значении фазы напряжения ~0,36π.

Разгон двигателя завершается примерно на отметке времени 2,5 мс, изменение частоты сигнала Δf во время разгона 23,7 кГц/с.

Как видно из рис. 3, ИНС достаточно достоверно фиксирует момент окончания разгона, при этом есть задержка в 0,83 мс в определении начала разгона. Нейросеть, которая обучена определять скорость изменения частоты, определяет окончание изменения частоты уже на отметке времени 1,88 мс. Эти задержки определяются размерами скользящего окна и могут быть учтены при обработке сигналов.




Рис. 3. ИНС – контроль тока при включении через тиристорный регулятор:
 А – ток в статоре; В – ток без регулирования;
 С – фиксация начала и конца разгонного режима; D – скорость разгона

Как видно из кривой D для скорости изменения частоты, значения Δf варьируются приблизительно на 10% при смещении окна наблюдения. Данная погрешность может быть значительно уменьшена при фильтрации по нескольким точкам [28].

Таким образом, в работе использовано две нейронных сети разной конфигурации, одна из которых решает классификационную, другая – регрессионную задачу. Характерные задержки в определении параметров нестационарных сигналов сопоставимы с длительностью скользящего окна наблюдения. В данном случае временные задержки не превышали 1/10 периода сигналов промышленной частоты.

Для определения разных параметров сигнала могут потребоваться окна наблюдений разной длительности [2, 7]. Кроме того, при наличии шума может возникать необходимость усреднения результатов или фильтрации по нескольким точкам, соответствующим смещению временного окна.

Несколько нейронных сетей могут быть занесены и запрограммированы в одном микропроцессорном устройстве. Результаты, полученные разными ИНС, могут дополнять друг друга.

Контроль частотных характеристик сигналов в электродвигателе [5, 21] в течение одного периода промышленной частоты может быть полезен в задачах управления вентилями двигателя и контроля за ними [3], для ШИМ-управления в цепях с полупроводниковыми элементами [10], где сигналы могут сильно отличаться от гармонических и иметь широкий спектр.

Выводы. Предлагаемый подход позволяет контролировать частотные характеристики электрических сигналов в течение одного периода с задержкой в единицы миллисекунд. Обучение нейронных сетей проводится при помощи

простых аналитических формул и может быть реализовано в широком диапазоне варьирования параметров сигналов. Для решения поставленных задач могут одновременно использоваться несколько простейших нейронных сетей, получаемые при этом результаты могут дополнять и уточнять друг друга.

Литература

1. Андреев О.Н., Ксенофонтов С.И., Славутский А.Л. Моделирование и нейросетевая обработка сигналов при переходных процессах в электротехнических комплексах. Чебоксары: Чуваш. гос. пед. ун-т, 2023. 212 с.

2. Андреев О.Н., Славутский Л.А., Тутаев Г.М., Васильева Л.Н. Локализация момента начала переходного процесса нейросетевыми программно-аппаратными средствами // Электротехника. 2023. № 8. С. 20–24. DOI: 10.3103/s1068371223080023.

3. Афанасьев А.А. Расчёт магнитоэлектрических вентильных двигателей методом разделения переменных Фурье // Электротехника. 2021. № 2. С. 21–27.

4. Афанасьев А.Ю., Макаров В.Г., Ханнанова В.Н. Идентификация параметров трехфазного асинхронного двигателя при изменении начальных значений оценок в широком диапазоне // Известия высших учебных заведений. Проблемы энергетики. 2015. № 11-12. С. 87–96.

5. Булычев А.В., Грибков М.А. Анализ процессов самозапуска электродвигателей в современных электрических распределительных сетях с позиций релейной защиты // Релейная защита и автоматизация. 2023. № 1(50). С. 30–38.

6. Ившин И.В., Аухадеев А.Э., Ле К.Т. О применении нейронных сетей в расчетах рациональных режимов работы тягового электрооборудования городского электрического транспорта // Вестник Казанского государственного энергетического университета. 2023. Т. 15, № 1(57). С. 106–116.

7. Лямец Ю.Я., Воронов П.И., Мартынов М.В., Маслов А.Н. Обучение релейной защиты на малом окне наблюдения // Электричество. 2017. № 3. С. 28–33.

8. Нейросетевой алгоритм восстановления в реальном времени сигнала промышленной частоты при нелинейных искажениях / А.Л. Славутский, Л.А. Славутский, В.В. Алексеев [и др.] // Электротехника. 2021. № 8. С. 21–25.

9. Омельченко Е.Я., Лымарь А.Б. Идентификация параметров схемы замещения асинхронных двигателей при помощи нейронных сетей // Электротехнические и информационные комплексы и системы. 2023. Т. 19, № 4. С. 31–44. DOI: 10.17122/1999-5458-2023-19-4-31-44.

10. Славутский А.Л. Применение алгоритма Доммеля для моделирования цепи с полупроводниковыми элементами и ключами с ШИМ управлением // Вестник Чувашского университета. 2014. № 2. С. 57–65.

11. Солдатов А.А., Евдокимов Ю.К. Нейросетевой метод контроля режимов работы подстанционных информационно-измерительных комплексов учета электроэнергии // Промышленные АСУ и контроллеры. 2017. № 11. С. 35–49.

12. Akchurin D., Bashirov M., Volkova O. et al. Development and research of an intelligent diagnostic system for equipment of electric power complexes. In: E3S Web Conf: III International Conference on Actual Problems of the Energy Complex: Mining, Production, Transmission, Processing and Environmental Protection (ICAPE2024), 2024, vol. 498. 01003. DOI: 10.1051/e3sconf/202449801003.

13. Arredondo L.R., Esparza D., Medina G.J.M. et al. Power Factor Prediction in Three Phase Electrical Power Systems Using Machine Learning. *Sustainability*, 2022, vol. 14. 9113. DOI: 10.3390/su14159113.

14. Bezduzhny D., Kulikov A., Loskutov A., Petrov I. Decision Tree Models and Machine Learning Algorithms in the Fault Recognition on Power Lines with Branches. *Energies*, 2023, vol. 16. 5563.

15. Bezerra U.H., Rozal Filho E.O., Manito A.R. et al. Harmonic classifier for efficiency induction motors using ANN. *Revista Contemporânea*, 2023, vol. 3(10), pp. 17660–17678. DOI: 10.56083/RCV3N10-054.

16. Bhattacharya B., Sinha A. Intelligent Fault Analysis in Electrical Power Grids. In: IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI), 2017, pp. 985–990. DOI: 10.1109/ICTAI.2017.00151.

17. Bouktif S., Fiaz A., Ouni A., Serhani M.A. Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm. In: Comparison with Machine Learning Approaches. *Energies*, 2018, vol. 11(7), 1636. DOI: 10.3390/en11071636.
18. Burton B., Harley R.G. Reducing the computational demands of continually online-trained artificial neural networks for system identification and control of fast processes. In: *IEEE Transactions on Industry Applications*, 1998, vol. 34(3), pp. 589–596.
19. Cardoso R.T.N., Rocha S.A., Mattos T.G., Silveira E.G. Applying Artificial Neural Networks and Nonlinear Optimization Techniques to Fault Location in Transmission Lines – Statistical Analysis. *Energies*, 2022, vol. 15. 4095. DOI: 10.3390/en15114095.
20. Dharmendra K., Moushmi K., Zadgaonkar A.S. Analysis of generated harmonics due to transformer load on power system using artificial neural network. *International journal of electrical engineering*, 2013, vol. 4(1), pp. 81–90.
21. Dong X., Chen Y., Niu G. Motor Fault Diagnostics Based on Current Signatures. In: *IEEE Transactions on Instrumentation and Measurement*, 2023, vol. 72, pp. 1–19. DOI: 10.1109/TIM.2023.3285999.
22. Leonowicz Z., Jasinski M. Machine Learning and Data Mining Applications in Power Systems. *Energies*, 2022, vol. 15. 1676. DOI: 10.3390/en15051676.
23. Noebels M., Panteli M.A., Preece R. Machine learning approach for real-time selection of preventive actions improving power network resilience. In: *IET Gener. Transmiss. Distrib.*, 2022, vol. 16, no. 1, pp. 181–192.
24. Omelchenko E., Lyamar A. Development of a New System for the Asynchronous Motor Parameters Identification based on Neural Networks. *Russian Workshop on Power Engineering and Automation of Metallurgy Industry: Research & Practice (PEAMI)*, 2023, pp. 72–79.
25. Osowski S., Szurlo R., Siwek K., Ciecchulski T. Neural Approaches to Short-Time Load Forecasting in Power Systems – A Comparative Study. *Energies*, 2022, vol. 15, 3265. DOI: 10.3390/en15093265.
26. Pawlik P., Kania K., Przysucha B. Fault diagnosis of machines operating in variable conditions using artificial neural network not requiring training data from a faulty machine. *Eksploatacja i Niezawodność – Maintenance and Reliability*, 2023, vol. 25(3), 168109. DOI: 10.17531/ein/168109.
27. Rhmaan A., Srikumar V., Smith D.A. Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks. *Applied Energy*, 2018, vol. 212, pp. 372–385. DOI: 10.1016/j.apenergy.2017.12.051.
28. Slavutskii L.A., Lazareva N.M., Portnov M.S., Slavutskaya E.V. Neural net without "deep learning": signal approximation by multilayer perceptron. In: *2nd International Conference on Computer Applications for Management and Sustainable Development of Production and Industry (CMSD-II-2022)*, 2023, 125640P. DOI: 10.1117/12.2669233.
29. Yan Y., Chen K., Geng H. et al. Review on Intelligent Detection and Classification of Power Quality Disturbances: Trends, Methodologies, and Prospects. *CMES-Computer Modeling in Engineering & Sciences*, 2023, vol. 137(2), pp. 1345–1379.
30. Zayer W., Radhi A. Faults diagnosis in stator windings of high speed solid rotor induction motors using fuzzy neural network. *International Journal of Power Electronics and Drive Systems (IJPEDS)*, 2021, vol. 12(1), pp. 597–611.

АНДРЕЕВ ОЛЕГ НИКОЛАЕВИЧ – аспирант кафедры автоматике и управления в технических системах, Чувашский государственный университет, Россия, Чебоксары (helga013@yandex.ru; ORCID: <https://orcid.org/0000-0003-2974-2502>).

АНДРЕЕВ ВЯЧЕСЛАВ ВЛАДИМИРОВИЧ – студент II курса магистратуры факультета радиоэлектроники и автоматике, Чувашский государственный университет, Россия, Чебоксары (vyacheslav-andreev-2000@mail.ru).

РУССОВА НАТАЛИЯ ВАЛЕРЬЕВНА – кандидат технических наук, доцент кафедры электрических и электронных аппаратов, Чувашский государственный университет, Россия, Чебоксары (russova@mail.ru; ORCID: <https://orcid.org/0009-0002-1217-8685>).

СЛАВУТСКИЙ АЛЕКСАНДР ЛЕОНИДОВИЧ – кандидат технических наук, заместитель начальника отдела разработки программных продуктов, Обособленное подразделение ООО «Юнител Инжиниринг», Россия, Чебоксары (slavutskii@gmail.com; ORCID: <https://orcid.org/0000-0002-6315-2445>).

Oleg N. ANDREEV, Vyacheslav V. ANDREEV,
Nataliya V. RUSSOVA, Aleksandr L. SLAVUTSKIY

**MONITORING OF NON-STATIONARY SIGNALS WITH MINIMAL DELAY:
NEURAL NETWORK IMPLEMENTATION**

Key words: neural networks, microprocessor implementation, non-stationary signals, time window.

In electrical and power engineering, Fourier transform algorithms are widely used to analyze current and voltage signals. This leads to a time delay in determining the parameters, which is at least the period of the industrial frequency signal. For a number of tasks, it is relevant to determine the parameters of non-stationary signals with minimal delay.

The purpose of the study is to show the possibility of the signals parameters monitoring over a time interval in a fraction of the period of industrial frequency based on the microprocessor implementation of neural network algorithms.

Materials and methods. The software and hardware are implemented in standard microprocessor equipment based on the simplest neural networks of direct propagation. The experimental verification of the algorithms was carried out in laboratory conditions using the example of monitoring current signals in an asynchronous motor when power is off and on during one period of industrial frequency.

Results. It is shown that the proposed approach makes it possible to record the onset of transients and the rate of change in the frequency of signals during a time window of about a millisecond. At the same time, neural networks of different structures can be used simultaneously. The calculation time of a trained neural network corresponds to real-time signal processing.

Conclusions. Neural networks are trained using simple analytical formulas and can be implemented in a wide variation range of signal parameters. Since several simple neural networks can be used simultaneously to solve the tasks, the results obtained can complement and refine each other.

References

1. Andreev O.N., Ksenofontov S.I., Slavutskii A.L. *Modelirovanie i neurosetevaya obrabotka signalov pri perekhodnykh protsessakh v elektrotekhnicheskikh kompleksakh* [Modeling and neural network signal processing at transient processes in electrical complexes]. *Cheboksary*, 2023, 212 p.
2. Andreev O.N., Slavutskii L.A., Tutaev G.M., Vasil'eva L.N. *Lokalizatsiya momenta nachala perekhodnogo protsessa neurosetevymi programmno-apparatnymi sredstvami* [Transients initial stage localization by neural net software and hardware]. *Elektrotehnika*, 2023, no. 8, pp. 20–24. DOI: 10.3103/s1068371223080023.
3. Afanas'ev A.A. *Raschet magnitoelektricheskikh ventil'nykh dvigatelei metodom razdeleniya peremennykh Fur'e* [Calculating magnetoelectric valve motors by the Fourier variable separation method]. *Elektrotehnika*, 2021, no. 2, pp. 21–27.
4. Afanas'ev A.Yu., Makarov V.G., Khannanova V.N. *Identifikatsiya parametrov trekhfaznogo asinkhronnogo dvigatelya pri izmenenii nachal'nykh znachenii otsenok v shirokom diapazone* [Identification of parameters of a three-phase asynchronous motor when changing the initial values of the estimates in a wide range]. *Izvestiya vysshikh uchebnykh zavedenii. Problemy energetiki*, 2015, no. 11-12, pp. 87–96.
5. Bulychev A.V., Gribkov M.A. *Analiz protsessov samozapuska elektrodvigatelei v sovremennykh elektricheskikh raspredelitel'nykh setyakh s pozitsii releinoi zashchity* [Analysis of self-starting processes of electric motors in modern electrical distribution networks from the perspective of relay protection]. *Releynaya zashchita i avtomatizatsiya*, 2023, no. 1(50), pp. 30–38.
6. Ivshin I.V., Aukhadeev A.E., Le K.T. *O primenении neuronnykh setei v raschetakh ratsional'nykh rezhimov raboty tyagovogo elektrooborudovaniya gorodskogo elektricheskogo transporta* [Application of neural networks in rational modes calculations of traction electric equipment operation of urban electric transport]. *Vestnik Kazanskogo gosudarstvennogo energeticheskogo universiteta*, 2023, vol. 15, no. 1(57), pp. 106–116.

7. Lyamets Yu.Ya., Voronov P.I., Martynov M.V., Maslov A.N. *Obuchenie releinoi zashchity na malom okne nablyudeniya* [Training of relay protection with small observation window]. *Elektrichestvo*, 2017, no. 3, pp. 28–33.
8. Slavutskii A.L., Slavutskii L.A., Alekseev V.V. et al. *Neuroseteivoi algoritm vosstanovleniya v real'nom vremeni signala promyshlennoi chastoty pri nelineinykh iskazheniyakh* [A neural-network algorithm for real-time recovery of an industrial-frequency signal upon nonlinear distortions]. *Elektrotehnika*, 2021, no. 8, pp. 21–25.
9. Omel'chenko E.Ya., Lyamar' A.B. *Identifikatsiya parametrov skhemy zameshcheniya asinkhronnykh dvigatelei pri pomoshchi neuronnykh setei* [Identification of the parameters of an induction motor equipment circuit using neural networks]. *Elektrotehnicheskie i informatsionnye komplekсы i sistemy*, 2023, vol. 19, no. 4, pp. 31–44. DOI: 10.17122/1999-5458-2023-19-4-31-44.
10. Slavutskii A.L. *Primeneniye algoritma Dommelya dlya modelirovaniya tsepi s poluprovodnikovymi elementami i klyuchami s ShIM upravleniem* [Application of Dommel algorithm for simulation of semiconductor circuits with pwm control switches]. *Vestnik Chuvashskogo universiteta*, 2014, no. 2, pp. 57–65.
11. Soldatov A.A., Evdokimov Yu.K. *Neuroseteivoi metod kontrolya rezhimov raboty podstantsionnykh informatsionno-izmeritel'nykh kompleksov ucheta elektroenergii* [Neural network method of monitoring the operating modes of substation information-measuring systems for electricity metering]. *Promyshlennyye ASU i kontrolyery*, 2017, no. 11, pp. 35–49.
12. Akchurin D., Bashirov M., Volkova O. et al. Development and research of an intelligent diagnostic system for equipment of electric power complexes. In: E3S Web Conf: III International Conference on Actual Problems of the Energy Complex: Mining, Production, Transmission, Processing and Environmental Protection (ICAPE2024), 2024, vol. 498. 01003. DOI: 10.1051/e3sconf/202449801003.
13. Arredondo L.R., Esparza D., Medina G.J.M. et al. Power Factor Prediction in Three Phase Electrical Power Systems Using Machine Learning. *Sustainability*, 2022, vol. 14. 9113. DOI: 10.3390/su14159113.
14. Bezdushniy D., Kulikov A., Loskutov A., Petrov I. Decision Tree Models and Machine Learning Algorithms in the Fault Recognition on Power Lines with Branches. *Energies*, 2023, vol. 16. 5563.
15. Bezerra U.H., Rozal Filho E.O., Manito A.R. et al. Harmonic classifier for efficiency induction motors using ANN. *Revista Contemporânea*, 2023, vol. 3(10), pp. 17660–17678. DOI: 10.56083/RCV3N10-054.
16. Bhattacharya B., Sinha A. Intelligent Fault Analysis in Electrical Power Grids. In: IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI), 2017, pp. 985–990. DOI: 10.1109/ICTAI.2017.00151.
17. Bouktif S., Fiaz A., Ouni A., Serhani M.A. Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm. In: Comparison with Machine Learning Approaches. *Energies*, 2018, vol. 11(7), 1636. DOI: 10.3390/en11071636.
18. Burton B., Harley R.G. Reducing the computational demands of continually online-trained artificial neural networks for system identification and control of fast processes. In: IEEE Transactions on Industry Applications, 1998, vol. 34(3), pp. 589–596.
19. Cardoso R.T.N., Rocha S.A., Mattos T.G., Silveira E.G. Applying Artificial Neural Networks and Nonlinear Optimization Techniques to Fault Location in Transmission Lines – Statistical Analysis. *Energies*, 2022, vol. 15. 4095. DOI: 10.3390/en15114095.
20. Dharmendra K., Moushmi K., Zadgaonkar A.S. Analysis of generated harmonics due to transformer load on power system using artificial neural network. *International journal of electrical engineering*, 2013, vol. 4(1), pp. 81–90.
21. Dong X., Chen Y., Niu G. Motor Fault Diagnostics Based on Current Signatures. In: IEEE Transactions on Instrumentation and Measurement, 2023, vol. 72, pp. 1–19. DOI: 10.1109/TIM.2023.-3285999.
22. Leonowicz Z., Jasinski M. Machine Learning and Data Mining Applications in Power Systems. *Energies*, 2022, vol. 15. 1676. DOI: 10.3390/en15051676.
23. Noebels M., Panteli M.A., Preece R. Machine learning approach for real-time selection of preventive actions improving power network resilience. In: IET Gener. Transmiss. Distrib., 2022, vol. 16, no. 1, pp. 181–192.

24. Omelchenko E., Lymar A. Development of a New System for the Asynchronous Motor Parameters Identification based on Neural Networks. Russian Workshop on Power Engineering and Automation of Metallurgy Industry: Research & Practice (PEAMI), 2023, pp. 72–79.

25. Osowski S., Szmurlo R., Siwek K., Ciechulski T. Neural Approaches to Short-Time Load Forecasting in Power Systems – A Comparative Study. *Energies*, 2022, vol. 15, 3265. DOI: 10.3390/en15093265.

26. Pawlik P., Kania K., Przysucha B. Fault diagnosis of machines operating in variable conditions using artificial neural network not requiring training data from a faulty machine. *Eksploatacja i Niezawodność – Maintenance and Reliability*, 2023, vol. 25(3), 168109. DOI: 10.17531/ein/168109.

27. Rhmaan A., Srikumar V., Smith D.A. Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks. *Applied Energy*, 2018, vol. 212, pp. 372–385. DOI: 10.1016/j.apenergy.2017.12.051.

28. Slavutskii L.A., Lazareva N.M., Portnov M.S., Slavutskaya E.V. Neural net without "deep learning": signal approximation by multilayer perceptron. In: 2nd International Conference on Computer Applications for Management and Sustainable Development of Production and Industry (CMSD-II-2022), 2023, 125640P. DOI: 10.1117/12.2669233.

29. Yan Y., Chen K., Geng H. et al. Review on Intelligent Detection and Classification of Power Quality Disturbances: Trends, Methodologies, and Prospects. *CMES-Computer Modeling in Engineering & Sciences*, 2023, vol. 137(2), pp. 1345–1379.

30. Zayer W., Radhi A. Faults diagnosis in stator windings of high speed solid rotor induction motors using fuzzy neural network. *International Journal of Power Electronics and Drive Systems (IJPEDS)*, 2021, vol. 12(1), pp. 597–611.

OLEG N. ANDREEV – Post-Graduate Student, Department of Automation and Control in Technical Systems, Chuvash State University, Russia, Cheboksary (helga013@yandex.ru; ORCID: <https://orcid.org/0000-0003-2974-2502>).

VYACHESLAV V. ANDREEV – Master’s Program Student, Faculty of Radio Electronics and Automation, Chuvash State University, Russia, Cheboksary (vyacheslav-andreev-2000@mail.ru).

NATALIYA V. RUSSOVA – Candidate of Technical Sciences, Associate Professor, Department of Electrical and Electronic Devices, Chuvash State University, Russia, Cheboksary (russova@mail.ru; ORCID: <https://orcid.org/0009-0002-1217-8685>).

ALEKSANDR L. SLAVUTSKIY – Candidate of Technical Sciences, Deputy Head of Software Development, Separate Subdivision of Unitel Engineering LLC, Russia, Cheboksary (slavutskii@gmail.com; ORCID: <https://orcid.org/0000-0002-6315-2445>).

Формат цитирования: Андреев О.Н., Андреев В.В., Руссова Н.В., Славутский А.Л. Контроль нестационарных сигналов с минимальной задержкой: нейросетевая реализация // Вестник Чувашского университета. – 2024. – № 2. – С. 5–14. DOI: 10.47026/1810-1909-2024-2-5-14.