

DOI: 10.47026/1810-1909-2021-3-21-30

УДК 621.31:658.588.2:53.082.4:004.032.26

ББК 32.873

А.В. БЫЧКОВ, И.Ю. БЫЧКОВА, Н.Н. СУСЛОВА, К.К. АЛИМОВ

ИСПОЛЬЗОВАНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ОПРЕДЕЛЕНИЯ ГЛУБИНЫ И ЧАСТОТЫ МОДУЛЯЦИИ СИГНАЛА ПРИ УЛЬТРАЗВУКОВОМ ВИБРОКОНТРОЛЕ ЭЛЕКТРООБОРУДОВАНИЯ

Ключевые слова: искусственная нейронная сеть, виброконтроль, ультразвуковые импульсы, электрооборудование.

Аппарат искусственных нейронных сетей предлагается использовать для обработки сигналов при активном ультразвуковом (УЗ) виброконтроле электрооборудования. Особенностью применяемого нейросетевого алгоритма является то, что искомая информация о параметрах вибраций заложена в изменении фазы ультразвукового сигнала при его постоянной амплитуде. В этих условиях традиционный спектральный анализ сигналов требует высокой частоты оцифровки и значительной длительности записей. При использовании искусственных нейронных сетей прямого распространения с тремя скрытыми слоями показано, что для оценки нестационарной частоты и амплитуды вибрационного сигнала достаточно частоты оцифровки в 5-6 точек на период ультразвуковой волны с длительностью записи 4-5 периодов. Получены оценки погрешности при определении амплитуды, частоты и фазы вибраций. Среднеквадратичные ошибки нейросетевого алгоритма не превышают единиц процентов. Продемонстрированы возможности использования обученной нейронной сети при обработке сигналов в «скользящем окне». Обсуждаются точностные характеристики предлагаемого нейросетевого алгоритма обработки сигналов и возможности его оптимизации для виброконтроля электрооборудования.

Введение. Тенденции в области диагностики говорят о всевозрастающем интересе к использованию искусственных нейронных сетей (ИНС). Искусственная нейронная сеть является одной из составляющих искусственного интеллекта (ИИ) [16, 20, 21] и методов интеллектуального анализа данных (МИАД, data mining) [2, 8, 19, 23]. Такие сети используются при решении задач метеорологии [14], психодиагностики [6, 7], цифровой техники [3, 11, 15]. Одними из основных способов применения в цифровой технике являются цифровая обработки сигналов [12, 13, 17, 18] и их классификация применительно к различным процессам. В настоящей работе приводится пример использования ИНС прямого распространения с обратным распространением ошибки [14, 22] для определения ряда параметров вибрационных сигналов.

В теории вибродиагностики для анализа состояния машин, механизмов и другого оборудования используются три основных параметра: виброускорение, виброскорость и виброперемещение [4]. Виброперемещение – это по сути непосредственно характеристика колебания поверхности агрегата. Виброскорость и виброускорение – это первая и вторая её производные. Виброускорение – это характеристика вибрации, прямо пропорционально связанная с силой, вызвавшей вибрацию. Виброускорение характеризует силовое динамическое взаимодействие элементов внутри агрегата, которое вызвало данную виб-

рацию. Измерение виброускорения с практической точки зрения лишено дополнительных сложностей, так как стандартный пьезодатчик (акселерометр) измеряет именно ускорение и эту величину не нужно специально дополнительно преобразовывать. Виброскорость – это скорость перемещения контролируемой поверхности оборудования, т.е. иначе говоря – мощность вибрации. Виброперемещение показывает максимальные границы перемещения контролируемой точки в процессе вибрации. Это расстояние между крайними точками перемещения элемента оборудования вдоль оси измерения.

Теоретически измерение того или другого параметра определяется диапазоном частот вибрации. Для виброперемещения это вибрации с частотами до примерно 300–500 Гц. Для виброскорости – этот диапазон от 10 Гц до максимум 2000 Гц. Виброускорение измеряется при наличии вибрации в широкой полосе частот, как правило, на практике это от 1000 Гц. Верхний предел определяется возможностями измерительного прибора [4].

Как следствие, в спектрах этих величин наилучшим образом проявляются гармонические составляющие вибраций указанных диапазонов.

Активный ультразвуковой виброконтроль подразумевает бесконтактные измерения параметров вибраций. Это, с одной стороны, допускает его использование для контроля таких подвижных частей электрооборудования, как вращающиеся валы двигателей, с другой – обработка ультразвуковых сигналов позволяет оценить как динамические, так и кинематические характеристики вибраций.

В статье описан подход к измерениям параметров вибрационного сигнала (амплитуды, частоты, фазы) с использованием ИНС.

Методика дистанционного виброконтроля. Схема дистанционных измерений и моделирования ультразвуковой системы контроля вибраций показана на рис. 1.




Рис. 1. Схема измерений и обработки сигналов

Отражение ультразвуковой волны в численном эксперименте происходит от вибрирующей с переменной частотой f_v поверхности. Генератор (Г) формирует пакеты ультразвуковых импульсов с частотой 40 кГц. Акустическая волна излучается ультразвуковым преобразователем (УЗП), распространяется до вибрирующей поверхности и, отражаясь от неё, принимается вторым УЗП (приёмником).

Форма отраженного ультразвукового сигнала при синусоидальной вибрации показана на графике (рис. 2, *а*). На нем видна модуляция по фазе (частоте). На втором графике рис. 2, *а* показано изменение фазы этого сигнала во времени. Измерение производится в реальном времени, и в каждый момент времени обрабатывается выборка из 24 точек. Пример интервала ультразвукового сигнала из 24 точек показан на рис. 2, *б*. Поскольку фазовая модуляция ультразвукового сигнала определяется одновременно и частотой, и амплитудой вибраций, анализировать параметры такого сигнала классическими методами цифровой обработки сигналов затруднительно. Поэтому в статье предлагается метод, в основе которого лежит применение искусственной нейронной сети.

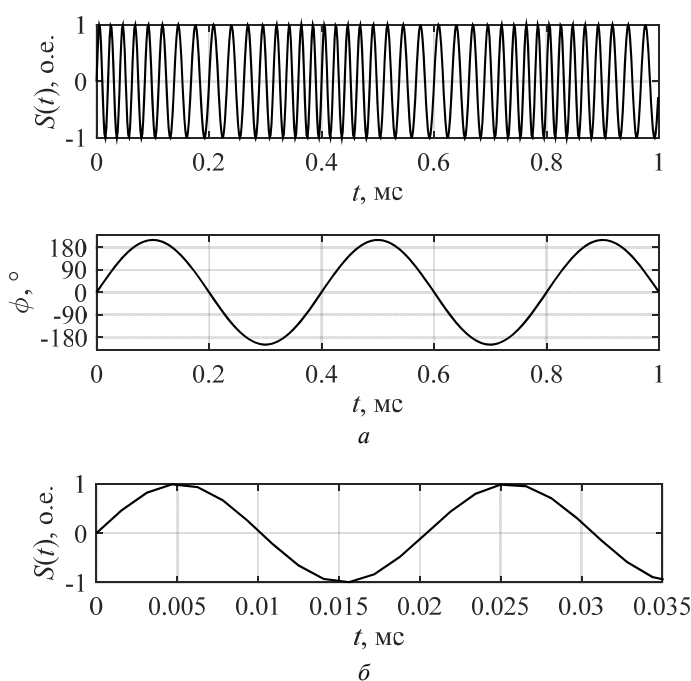


Рис. 2. Форма ультразвукового сигнала после отражения от вибрирующей стенки (сигнал с фазовой модуляцией), изменение фазы ультразвукового сигнала во времени (*а*); форма ультразвукового сигнала в скользящем окне (*б*)

Таким образом, электрический сигнал с выхода приёмного преобразователя (рис. 1) подается на вход искусственной нейронной сети (ИНС), где производится определение указанных параметров сигнала.

Цифровая система формирования и обработки сигналов частично реализована на программируемой логической интегральной схеме (FPGA – field-programmable gate array). Указанные программно-аппаратные средства были использованы в устройстве ультразвукового уровнемера [6] и устройстве контроля газовых потоков.

Моделирование рассеяния ультразвуковых импульсов на вибрирующей поверхности проводилось в лучевом приближении при задании формы ультразвукового сигнала по выражению [1]

$$S(t) = A \cdot \sin \left(\omega \left(t - \frac{2(L - \delta_V \cdot \sin(\omega_V t + \varphi_V))}{c} \right) \right), \quad (1)$$

где ω_V – циклическая частота колебаний поверхности $\omega_V = 2\pi f_V$; c – скорость звука; L – расстояние вдоль луча до поверхности; δ_V – проекция амплитуды колебаний поверхности на направление луча; φ_V – фаза колебаний поверхности; A – амплитуда УЗ импульса на опорной частоте сигнала $F = 40$ кГц.

Параметры δ_V , ω_V и φ_V в формуле (1) задавались в виде *равномерно распределенных в определенном диапазоне случайных величин*. Результаты расчетов использовались при создании выборки для обучения ИНС. Размер выборки – от 5000 записей. Адекватность моделирования (1) рассеянного ультразвукового сигнала проверена в экспериментальных условиях [9, 10].

Пример нейросетевой обработки сигналов. На рис. 3 представлена структура ИНС. Она имеет 24 входных нейрона (по числу отсчетов сигнала), 3 внутренних слоя: 30, 10 и 4 нейрона. Двадцать четыре входа соответствуют примерно четырём периодам ультразвукового сигнала основной частоты – 40 кГц. На выходе ИНС имеем три измеряемых параметра: амплитуду, частоту и начальную фазу. Сигнал на вход ИНС подается в каждый момент времени в режиме «скользящего окна». Соответственно на выходе определяются изменяющиеся во времени параметры.

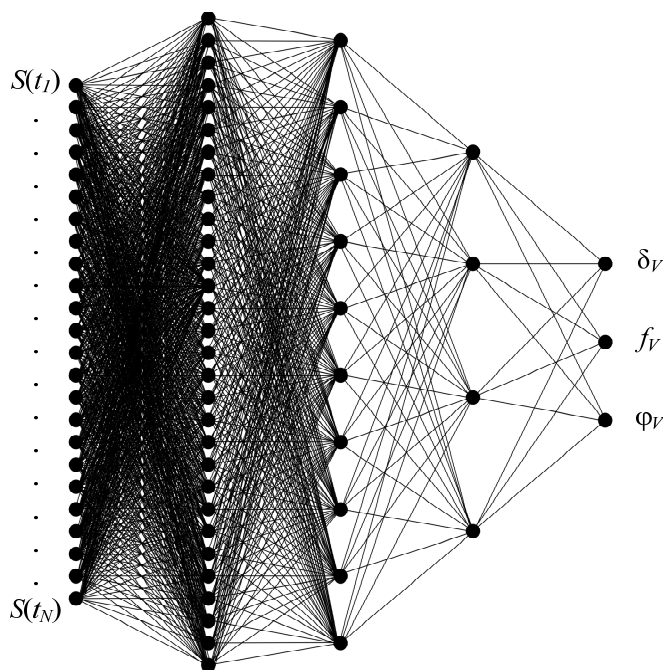


Рис. 3. Структура нейронной сети

Обучение нейронной сети, как упоминалось выше, производилось выборкой из минимум $N = 5000$ модельных сигналов ультразвуковой волны со случайными амплитудой, частотой и начальной фазой. Результаты обучения представлены на рис. 4.




Рис. 4. Гистограммы ошибок при обучении ИНС: для амплитуды (а), частоты (б) и начальной фазы (в). Сплошная кривая – сумма с накоплением

Так как число связей между нейронами (менее 1100) значительно меньше N , точность распознавания сигнала можно оценить по качеству обучения ИНС – гистограмме распределения среднеквадратичной ошибки. В таблице приведены значения максимальной и среднеквадратической ошибок ИНС для каждого из распознаваемых параметров. Распознаваемость во всех случаях превышала 95% при числе эпох (циклов) обучения более 500.

Как видно из таблицы и рис. 4, максимальные ошибки при обучении ИНС оказываются очень значительными – десятки процентов. Однако такие

ошибки возникают в достаточно редких случаях, и средние ошибки не превышают единиц процентов. Обучение ИНС при варьировании фазы вибраций в диапазоне от 0 до 2π позволяет исключить максимальные ошибки методом скользящего среднего или медианным сглаживанием в интервале времени, соответствующем длительности «скользящего окна» в несколько периодов ультразвукового сигнала.

Оценка качества обучения ИНС

Параметр	Максимальная ошибка (σ_{\max}), о.е.	Среднеквадратическая ошибка (σ_s), о.е.	Распознавание связей (S)
Амплитуда (δr)	0,31	0,024	95-96%
Частота (f)	0,42	0,032	95-96%
Фаза (φ)	0,17	0,013	95-96%

Для проверки работы нейроалгоритма после обучения ИНС на ее вход подавались сигналы отраженной от вибрирующей поверхности ультразвуковой волны (рис. 2). Входной нестационарный ультразвуковой сигнал имел изменяющуюся во времени модуляцию, которая соответствовала вибрационному сигналу при линейном изменении частоты вибрации от 800 до 1300 Гц, и амплитуды от 0,5 мм до 2,5 мм.

На рис. 5 показаны результаты использования ИНС в «скользящем окне» длительностью 100 мкс.




Рис. 5. Результаты применения ИНС для определения частоты вибраций (а); закон изменения фазы модулированного ультразвукового сигнала (б).

Пунктирная кривая – исходные данные,
сплошная кривая – по результатам на выходе ИНС

Как видно из рис. 5, ИНС позволяет восстановить плавное изменение частоты вибраций даже в том случае, когда изменение фазы УЗ сигнала определяется одновременно не только частотой, но и амплитудой вибраций. Квазипериодические осцилляции зависимости частоты на рис. 5, *а* связаны с временным смещением «скользящего окна» обработки сигнала и соответствующим смещением фазы. Коррекция и исключение этих осцилляций могут проводиться при использовании данных ИНС при пересчете (1). Поскольку точность определения параметров вибраций оказывается наиболее высокой для фазы (см. рис. 4, *в*), такая коррекция может повысить точность определения всех параметров. При этом возможные ограничения связаны прежде всего с используемыми для реализации нейросетевого алгоритма вычислительными мощностями и заданным быстродействием.

Выводы. Таким образом, ИНС прямого распространения (элементарный персептрон) позволяет при невысокой частоте дискретизации за временной интервал, соответствующий нескольким периодам ультразвуковых волн, определить частоту и глубину модуляции сигнала при рассеянии на вибрирующей поверхности. Показано, что алгоритм работает при плавном изменении частоты и амплитуды вибраций. Поскольку информация о параметрах вибраций заключена в изменении фазы УЗ сигнала при его постоянной амплитуде, полученные точностные характеристики нейросетевого алгоритма с погрешностью в единицы процентов могут считаться приемлемыми для практического использования. Обработка сигналов может проводиться в «скользящем окне», длительность которого может оптимизироваться в зависимости от параметров вибраций электрооборудования.

Литература

1. Бычков А.В., Славутский Л.А. Возможности корреляционной обработки импульсных ультразвуковых сигналов при бесконтактном виброконтроле оборудования электроэнергетики // Вестник Чувашиского университета. 2018. № 3. С. 24–32.
2. Дюк В., Самойленко А. Data Mining. СПб.: Питер, 2001. 386 с.
3. Костюкова Н.И. Система принятия решений в области медицинской диагностики и выбора оптимальных решений по технологии Data Mining // Открытое образование. 2010. Прил. С. 145–146.
4. Русов В.А. Диагностика дефектов вращающегося оборудования по вибрационным сигналам. Пермь: ДимРус, 2012. 200 с.
5. Славутский Л.А., Костюков А.С. Статистическая погрешность ультразвукового цифрового уровнемера с частотно-фазовой модуляцией сигнала // Приборы и системы. Управление, контроль, диагностика. 2009. № 8. С. 35–37.
6. Славутская Е.В., Аbruков В.С., Славутский Л.А. Простые нейросетевые алгоритмы для оценки латентных связей психологических характеристик младших подростков // Экспериментальная психология. 2019. Т. 12, № 2. С. 131–144.
7. Славутская Е.В., Славутский Л.А. О выборе структуры искусственных нейросетей и алгоритмов анализа психодиагностических данных // Казанский педагогический журнал. 2020. № 5(142). С. 202–211. DOI: 10.34772/KPJ.2020.142.5.026.
8. Финн В.К. Об интеллектуальном анализе данных // Новости искусственного интеллекта. 2004. № 3. С. 3–18.
9. Bychkov A., Bychkova I., Slavutskii L. Active Ultrasonic Vibration Control of Electrical Equipment: Correlation Signal Processing. In: 2019 International Ural Conference on Electrical Power Engineering (UralCon), 2019, pp. 244–248. DOI: 10.1109/URALCON.2019.8877666.

10. Bychkov A., Slavutskii L., Slavutskaya E. Neural network for pulsed ultrasonic vibration control of electrical equipment. In: 2020 International Ural Conference on Electrical Power Engineering (UralCon), 2020, pp. 24–28. DOI: 10.1109/UralCon49858.2020.9216248.
11. Dillon T.S., Niebur D. Neural Networks Application in Power Systems. London, CRL Ltd. Publishing, 1996.
12. Hinton G., Deng L., Yu D., Dahl G., Mohamed A., Jaitly N., Senior A., Vanhoucke V., Nguyen P., Sainath T., Kingsbury B. Deep Neural Networks for Acoustic Modeling in Speech Recognition – The shared views of four research groups. In: IEEE Signal Processing Magazine, iss. 29, no. 6, pp. 82–97. DOI: 10.1109/msp.2012.2205597.
13. Jambukia S.H., Dabhi V.K., Prajapati H.B. Classification of ECG signals using machine learning techniques: A survey. In: IEEE 2015 International Conference on Advances in Computer Engineering and Applications, 2015, pp. 714–721. DOI: 10.1109/ICACEA.2015.7164783.
14. Kakar S.A., Sheikh N., Naseem A., Iqbal S., Rehman A., Kakar A., Kakar B.A., Kakar H.A., Khan B. Artificial Neural Network based Weather Prediction using Back Propagation Technique. *International Journal of Advanced Computer Science and Applications*, 2018, iss. 9, no. 8, pp. 462–470. DOI: 10.14569/IJACSA.2018.090859.
15. Kezunovic M. A Survey of Neural Net Applications to Protective Relaying and Fault Analysis. *Engineering Intelligent Systems*, 1997, iss. 5, no. 4, pp. 185–192.
16. Kumar K., Thakur G.S.M. Advanced Applications of Neural Networks and Artificial Intelligence: A Review. *International Journal of Information Technology and Computer Science*, 2012, no. 6, pp. 57–68. DOI: 10.5815/ijitcs.2012.06.08.
17. LeCun Y., Bengio Y. Convolutional Networks for Images, Speech, and Time-Series. In: Arbib M.A., ed. *The Handbook of Brain Theory and Neural Networks*. Cambridge, MIT Press, 1995.
18. Matti D., Ekenel H.K., Thiran J.P. Combining LiDAR space clustering and convolutional neural networks for pedestrian detection. In: 14th IEEE International Conference on Advanced Video and Signal Based Surveillance, 2017, pp. 1–6. DOI: 10.1109/AVSS.2017.8078512.
19. Petrushin V.A., Khan L. *Multimedia Data Mining and Knowledge Discovery*. New York, Springer-Verlag, 2006. 539 c.
20. Samarasinghe S. *Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition*. 1st ed. Boca Raton, Auerbach Publications, 2006, 570 c.
21. Schmidhuber J. Deep Learning in Neural Networks: An Overview. *Neural Networks*, 2014, no. 61, pp. 85–117. DOI: 10.1016/j.neunet.2014.09.003.
22. Su H., Li G., Yu D., Seide F. Error back propagation for sequence training of context-dependent deep networks for conversational speech transcription. In: *Proceedings of International Conference on Acoustics Speech and Signal Processing (ICASSP)*, 2013, pp. 6664–6668.
23. Witten I.H., Frank E., Hall M.A., Kaufmann M. *Data Mining: Practical Machine Learning Tools and Techniques*. 3rd ed. Amsterdam, Elsevier, 2011, 629 p.

БЫЧКОВ АНАТОЛИЙ ВЛАДИМИРОВИЧ – аспирант кафедры электрических и электронных аппаратов, Чувашский государственный университет, Россия, Чебоксары (bav.xlab@gmail.com; ORCID: <https://orcid.org/0000-0003-2674-8626>).

БЫЧКОВА ИРИНА ЮРЬЕВНА – аспирантка кафедры автоматики и управления в технических системах, Чувашский государственный университет, Россия, Чебоксары (biy.quint@gmail.com; ORCID: <https://orcid.org/0000-0001-9852-3288>).

СУСЛОВА НАДЕЖДА НИКОЛАЕВНА – магистрантка факультета радиоэлектроники и автоматики, Чувашский государственный университет, Россия, Чебоксары (suslova.nadeshda@yandex.ru).

АЛИМОВ КУРБАНГАЛИ КАМАРТДИНОВИЧ – кандидат физико-математических наук, доцент кафедры прикладной физики и нанотехнологий, Чувашский государственный университет, Россия, Чебоксары (alimkur55@mail.ru).

Anatoly V. BYCHKOV, Irina Yu. BYCHKOVA,
Nadezhda N. SUSLOVA, Kurbangali K. ALIMOV
NEURAL NET USING TO DETERMINE DEPTH
AND FREQUENCY OF SIGNALS' MODULATION
FOR ELECTRICAL EQUIPMENT ULTRASONIC VIBROCONTROL

Key words: artificial neural network, vibration control, ultrasonic pulses, electrical equipment.

The apparatus of artificial neural networks (ANN) is proposed to be used for signal processing in active ultrasonic (US) vibration control of electrical equipment. A feature of the applied neural network algorithm is that the required information about vibration parameters is embedded in the ultrasound signal's phase change at its constant amplitude. Under these conditions, traditional spectral analysis of signals requires a high sampling rate and a significant recording duration. When using the direct propagation's ANN with three hidden layers, it was shown that it is sufficient to use a sampling frequency of 5-6 points for the period of an ultrasonic wave and a recording duration of 4-5 periods to estimate the nonstationary frequency and amplitude of the vibration signal. Estimates of the error in determining the amplitude, frequency and phase of vibrations are obtained. The root-mean-square errors of the neural network algorithm do not exceed units of percent. The possibilities of using a trained neural network for signal processing in a "sliding window" are demonstrated. The accuracy characteristics of the proposed neural network algorithm of signal processing and the possibility of its optimization for electrical equipment's vibration control are discussed.

References

1. Bychkov A.V., Slavutskii L.A. *Vozможности korrelyatsionnoi obrabotki impul'snykh ul'trazvukovykh signalov pri beskontaktnom vibrokontrole oborudovaniya ehlektroehnergetiki* [Capabilities of correlation processing of pulse ultrasonic signals for noncontact vibration control of electric power industry equipment]. *Vestnik Chuvashskogo universiteta*, 2018, no. 3, pp. 24–32.
2. Dyuk V., Samoilenko A. *Data Mining* [Data mining]. St. Petersburg, Piter Publ., 2001, 386 p.
3. Kostyukova N.I. *Sistema prinyatiya reshenii v oblasti meditsinskoi diagnostiki i vybora optimal'nykh reshenii po tekhnologii Data Mining* [Decision-making system in the field of medical diagnostics and selection of optimal solutions using Data Mining technology]. *Otkrytoe obrazovanie*, 2010, App., pp. 145–146.
4. Rusov V.A. *Diagnostika defektov vrashchayushchegosya oborudovaniya po vibratsionnym signalam* [Diagnosis of defects in rotating equipment by vibration signals]. Perm, DimRus Publ., 2012, 200 p.
5. Slavutskii L.A., Kostyukov A.S. *Statisticheskaya pogreshnost' ul'trazvukovogo tsifrovogo urovnemera s chastotno-fazovoi modulyatsiei signala* [Statistical error of an ultrasonic digital level meter with frequency-phase modulation of the signal]. *Pribory i sistemy. Upravlenie, kontrol', diagnostika*, 2009, no. 8, pp. 35–37.
6. Slavutskaya E.V., Abruков V.S., Slavutskii L.A. *Prostye neurosetevye algoritmy dlya ocenki latentnykh svyazei psikhologicheskikh kharakteristik mladshikh podrostkov* [Simple neuro network algorithms for evaluating latent links of younger adolescent's psychological characteristics]. *Ekspериментальная psihologiya*, 2019, vol. 12, no. 2, pp. 131–144.
7. Slavutskaya E.V. *O vybore struktury iskusstvennykh nejrosetei i algoritmov analiza psikhodiagnosticheskikh dannykh* [On choosing the artificial neural networks structure and the algorithms for psycho diagnostic data analyzing]. *Kazanskii pedagogicheskii zhurnal*, 2020, no. 5(142), pp. 202–211. DOI: 10.34772/KPJ.2020.142.5.026.
8. Finn V.K. *Ob intellektual'nom analize dannykh* [About data mining]. *Novosti iskusstvennogo intellekta*, 2004, no. 3, pp. 3–18.
9. Bychkov A., Bychkova I., Slavutskii L. Active Ultrasonic Vibration Control of Electrical Equipment: Correlation Signal Processing. In: 2019 International Ural Conference on Electrical Power Engineering (UralCon), 2019, pp. 244–248. DOI: 10.1109/URALCON.2019.8877666.

10. Bychkov A., Slavutskii L., Slavutskaya E. Neural network for pulsed ultrasonic vibration control of electrical equipment. In: 2020 International Ural Conference on Electrical Power Engineering (UralCon), 2020, pp. 24–28. DOI: 10.1109/UralCon49858.2020.9216248.
11. Dillon T.S., Niebur D. Neural Networks Application in Power Systems. London, CRL Ltd. Publishing, 1996.
12. Hinton G., Deng L., Yu D., Dahl G., Mohamed A., Jaitly N., Senior A., Vanhoucke V., Nguyen P., Sainath T., Kingsbury B. Deep Neural Networks for Acoustic Modeling in Speech Recognition – The shared views of four research groups. In: IEEE Signal Processing Magazine, iss. 29, no. 6, pp. 82–97. DOI: 10.1109/msp.2012.2205597.
13. Jambukia S.H., Dabhi V.K., Prajapati H.B. Classification of ECG signals using machine learning techniques: A survey. In: IEEE 2015 International Conference on Advances in Computer Engineering and Applications, 2015, pp. 714–721. DOI: 10.1109/ICACEA.2015.7164783.
14. Kakar S.A., Sheikh N., Naseem A., Iqbal S., Rehman A., Kakar A., Kakar B.A., Kakar H.A., Khan B. Artificial Neural Network based Weather Prediction using Back Propagation Technique. *International Journal of Advanced Computer Science and Applications*, 2018, iss. 9, no. 8, pp. 462–470. DOI: 10.14569/IJACSA.2018.090859.
15. Keszunovic M. A Survey of Neural Net Applications to Protective Relaying and Fault Analysis. *Engineering Intelligent Systems*, 1997, iss. 5, no. 4, pp. 185–192.
16. Kumar K., Thakur G.S.M. Advanced Applications of Neural Networks and Artificial Intelligence: A Review. *International Journal of Information Technology and Computer Science*, 2012, no. 6, pp. 57–68. DOI: 10.5815/ijitcs.2012.06.08.
17. LeCun Y., Bengio Y. Convolutional Networks for Images, Speech, and Time-Series. In: Arbib M.A., ed. *The Handbook of Brain Theory and Neural Networks*. Cambridge, MIT Press, 1995.
18. Matti D., Ekenel H.K., Thiran J.P. Combining LiDAR space clustering and convolutional neural networks for pedestrian detection. In: 14th IEEE International Conference on Advanced Video and Signal Based Surveillance, 2017, pp. 1–6. DOI: 10.1109/AVSS.2017.8078512.
19. Petrushin V.A., Khan L. *Multimedia Data Mining and Knowledge Discovery*. New York, Springer-Verlag, 2006. 539 c.
20. Samarasinghe S. *Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition*. 1st ed. Boca Raton, Auerbach Publications, 2006. 570 c.
21. Schmidhuber J. Deep Learning in Neural Networks: An Overview. *Neural Networks*, 2014, no. 61, pp. 85–117. DOI: 10.1016/j.neunet.2014.09.003.
22. Su H., Li G., Yu D., Seide F. Error back propagation for sequence training of context-dependent deep networks for conversational speech transcription. In: *Proceedings of International Conference on Acoustics Speech and Signal Processing (ICASSP)*, 2013, pp. 6664–6668.
23. Witten I.H., Frank E., Hall M.A., Kaufmann M. *Data Mining: Practical Machine Learning Tools and Techniques*. 3rd ed. Amsterdam, Elsevier, 2011, 629 p.

ANATOLY V. BYCHKOV – Post-Graduate Student of Electrical and Electronic Apparatuses Department, Chuvash State University, Russia, Cheboksary (bav.xlab@gmail.com; ORCID: <https://orcid.org/0000-0003-2674-8626>).

IRINA Yu. BYCHKOVA – Post-Graduate Student, Department of Automation and Control in Technical Systems, Chuvash State University, Russia, Cheboksary (biy.quint@gmail.com; ORCID: <https://orcid.org/0000-0001-9852-3288>).

NADEZHDA N. SUSLOVA – Master's Program Student, Faculty of Radio Electronics and Automation, Chuvash State University, Russia, Cheboksary (suslova.nadeshda@yandex.ru).

KURBANGALI K. ALIMOV – Candidate of Physical and Mathematical Sciences, Associate Professor of the Department of Applied Physics and Nanotechnology, Chuvash State University, Russia, Cheboksary (alimkur55@mail.ru).

Формат цитирования: Бычков А.В., Быčkoвa И.Ю., Суслова Н.Н., Алимов К.К. Использование нейронной сети для определения глубины и частоты модуляции сигнала при ультразвуковом виброконтроле электрооборудования // Вестник Чувашского университета. – 2021. – № 3. – С. 21–30. DOI: 10.47026/1810-1909-2021-3-21-30.