

УДК 621.316.91

ББК 31.247

Л.А. СЛАВУТСКИЙ, Е.В. СЛАВУТСКАЯ

**ВЫБОР СТРУКТУРЫ НЕЙРОННОЙ СЕТИ  
ДЛЯ ОБРАБОТКИ СИГНАЛОВ  
КАК ПЛАНИРОВАНИЕ ЭКСПЕРИМЕНТА**

*Ключевые слова:* искусственные нейронные сети, выбор структуры нейросети, планирование эксперимента, обработка сигналов в электротехнике, оценка точности нейроалгоритма.

*Работа посвящена использованию аппарата искусственных нейронных сетей для обработки сигналов в электротехнике и электроэнергетике. Нейронная сеть прямого распространения (персептрон) рассматривается как объект в теории планирования эксперимента. Анализируются варианты эмпирического выбора структуры нейронной сети, критерии качества ее обучения и тестирования. Показано, что выбор структуры персептрона, обучающей выборки и алгоритмов обучения требуют планирования. Обсуждаются переменные и параметры нейроалгоритмов, которые могут выступать в роли факторов, параметров состояния и возмущающих воздействий в рамках теории планирования эксперимента. Предлагаемый подход демонстрируется на примере нейросетевого анализа нелинейных искажений сигнала промышленной частоты 50 Гц. Анализируется возможность использования элементарного персептрона с одним скрытым слоем и минимальным количеством нейронов для коррекции тока насыщения трансформатора. Выявлены условия, при которых нейроалгоритм позволяет восстановить значения амплитуды, частоты и фазы основной гармоники с погрешностью не более единиц процентов. Предлагается обработка сигнала в «скользящем окне» длительностью в доли периода основной частоты, сделаны оценки точностных характеристик нейроалгоритма. Обсуждается возможность автоматизации выбора структуры нейронной сети для обработки сигналов.*

Методы машинного обучения, искусственного интеллекта и, в частности, аппарат искусственных нейронных сетей (ИНС) находят все более широкое применение в задачах электротехники и электроэнергетики [12, 15, 16, 18, 20]. В электроэнергетике ИНС используются для анализа качества электроэнергии [14, 23], идентификации аварийных режимов [4, 9–11], определения места повреждения [19, 21, 28, 30]. Они могут использоваться для структурного анализа сигналов и их обработки [17, 25, 26, 29], поскольку после обучения ИНС позволяют проводить быстрые вычисления. Для анализа случайных динамических процессов чаще используют рекуррентные нейронные сети [2, 7] с обратными связями и с учетом запоминания предшествующих параметров динамического процесса.

Выбор структуры нейронной сети и параметров обучающей выборки всегда осуществляется эмпирически. Это является важнейшей задачей использования аппарата ИНС. Обучение простейших ИНС прямого распространения (feedforward) не зависит от того, в какой последовательности на ее вход подаются примеры из обучающей выборки [2, 5]. Поэтому структура ИНС должна быть связана с частотой дискретизации сигнала, его длительно-

стью и т.д. В настоящей работе на примере анализа электротехнических сигналов показано, что процесс выбора структуры ИНС и параметров ее обучения может рассматриваться как задача планирования эксперимента [24].

**Выбор структуры нейронной сети.** ИНС прямого распространения (элементарный персептрон Розенблатта [27]) может рассматриваться как «диффузный» объект в теории планирования эксперимента (рис. 1) [24]. Здесь  $X_i$  и  $Y_i$  – входные сигналы и целевая функция,  $W_i$  – возмущающие воздействия, или дискретно меняющиеся параметры. После того как проведен процесс обучения ИНС, она позволяет в режиме «Если то» (if then) строить зависимости между входными параметрами  $X_i$  (факторами) и выходными параметрами  $Y_i$  (состояния). Таким образом, ИНС позволяют решать задачи аппроксимации.




Рис. 1. ИНС как объект планирования эксперимента

Обучение ИНС сводится к нахождению экстремума функции от многих переменных, которыми являются веса синапсов искусственных нейронов. Эта задача решается чаще всего с использованием градиентных методов оптимизации [8, 24]. То есть даже сам процесс обучения ИНС можно отнести к задачам планирования эксперимента при оптимальных условиях. При этом требуется контроль качества нейросетевой модели по таким критериям «обучаемости», как вид диаграммы рассеяния и гистограммы распределения ошибок, включая оценки процента распознавания связей между нейронами, максимальные и среднеквадратичные ошибки [2, 5].

После оценки качества обучения ИНС по этим критериям она позволяет достаточно быстро и точно вычислять связи между входными и выходными данными. Принципиальным отличием от классической теории планирования эксперимента является то, что ИНС-модель не может быть записана аналитически. Даже при малом количестве нейронов в структуре персептрона зависимости строятся на основе нечеткой логики, оказываются сильно нелинейными. То есть в классическом понимании идентификация объекта в этом случае исключена. Это тем более относится к «глубокому обучению» ИНС как основе искусственного интеллекта [13].

Использование вышеперечисленных критериев позволяет осуществлять выбор нейросетевой модели: набор входных параметров, количество нейронов и слоев в ИНС, целевую функцию (рис. 2). Если при обучении нейронной

сети выявляются высокие ошибки и низкий процент распознавания связей, то говорить о зависимостях между входными и выходными параметрами объекта невозможно в принципе. А значит, и сам эмпирический выбор структуры ИНС может осуществляться с помощью методов планирования эксперимента. Дискретный набор количества нейронов и слоев может считаться, например, возмущающими воздействиями  $W_i$ , показанными на рис. 1. А целевыми функциями могут выступать ошибки при обучении ИНС или процент распознавания вычислительных путей (связей) между нейронами.




Рис. 2. Замена целевой функции и количества нейронов в скрытом слое элементарного персептрона. Увеличение количества скрытых слоев ИНС

Следовательно, с одной стороны, ИНС-модель может рассматриваться как классический объект («черный ящик») из теории планирования эксперимента. С другой стороны – выбор структуры ИНС и алгоритмов ее обучения осуществляется эмпирически и требует планирования. Эта процедура в определенных рамках может быть автоматизирована и оптимизирована.

**Пример обработки сигнала.** При коммутациях и возникновении аварийных режимов в электрических сетях возникают эффекты насыщения трансформаторов тока (ТТ), результатом которых является значительное нелинейное искажение тока во вторичной обмотке. Коррекция тока во вторичной обмотке ТТ является одной из важнейших задач при разработке быстродействующих дифференциальных защит [1, 3]. В настоящей работе предлагается использовать элементарный персептрон для решения этой задачи. Обучение и тестирование ИНС требуют значительной выборки записей сигнала. Величина этой выборки должна как минимум в несколько раз превышать количество связей между нейронами ИНС. Для ИНС (рис. 2) число таких связей и, соответственно, весовых коэффициентов, которые находятся при обучении нейросети, составляет от нескольких десятков. Поэтому и выборка обучающих примеров должна состоять из сотен записей сигналов. Поэтому моделирование ТТ проводилось сначала методом синтетических схем [6] для оценки диапазона варьирования параметров, а обучающая выборка моделировалась на качественном уровне для упрощения вычислений.

Для моделирования сигналов тока  $I_2(t)$  во вторичной обмотке ТТ использованы следующие простейшие формулы, качественно обеспечивающие в целом описание формы сигнала:

$$I_1(t) = A_r [\exp(-B_r \cdot t) - \cos(2\pi \cdot f \cdot t)];$$

$$H(t) \sim w_1 I_1(t); B = F(H);$$

$$I_2(t) = w_2 \cdot \frac{dB}{dt}, \quad (1)$$

где  $I_1(t)$  – ток в первичной обмотке ТТ, форма которого определяется промышленной частотой  $f = 50$  Гц, амплитудой основной гармоники  $A_r$  и аperiodической составляющей с постоянной времени  $\tau = 1 / B_r$ ;  $w_1, w_2$  – постоянные коэффициенты, пропорциональные числу витков в обмотках;  $B(H)$  – функция намагничивания сердечника, которая подбирается эмпирически, в простейшем случае – в виде арктангенса.

При использовании ИНС по дискретным значениям тока  $I_2(t)$  необходимо оценить параметры входного тока  $A_r, B_r$ , которые задаются в виде случайных чисел при ее обучении [6]. Они могут быть получены после коррекции тока во вторичной обмотке с учетом коэффициента трансформации и сдвига фазы в «идеальном» ТТ с линейной характеристикой. На рис. 3 приведены пример сигнала тока  $I_2(t)$  и его форма после коррекции, на рис. 4 – структура использованной ИНС.

На вход ИНС подаются временные отсчёты сигнала  $I_2(t)$  в соответствии с частотой его оцифровки. На выходе – искомые параметры  $I_1(t)$ . Число входных нейронов соответствует интервалу времени, за которое необходимо произвести коррекцию тока ТТ. Такая структура ИНС уже выбрана эмпирически. В частности, количество скрытых слоев и нейронов в единственном скрытом слое получено в результате их последовательного уменьшения. Критерием являлось 100%-ное распознавание связей и уровень ошибок при интервале оцифровки в половину периода основной частоты (среднеквадратичная ошибка не более 2%).




Рис. 3. Пример искажения сигнала тока при насыщении ТТ

Среднеквадратичные ошибки  $\sigma$  нейросетевого алгоритма при вычислении частоты и амплитуды гармонического сигнала при его оцифровке с дискретностью 32 точки на период в зависимости от количества использованных входных нейронов ИНС (интервала) показаны на рис. 5.




Рис. 4. ИНС для анализа параметров сигнала




Рис. 5. Зависимости средних ошибок обучения ИНС от интервала оцифровки: 1 – частота; 2 – амплитуда сигнала

Как видно из рис. 5, для частоты заданная точность в 2% достигается при  $N = 15$ , а для амплитуды – при  $N = 5$  (3,125 мс).

Характерные особенности обучения и погрешностей ИНС проявляются в диаграмме рассеяния при вычислении случайной фазы сигнала в диапазоне от 0 до  $2\pi$  (рис. 6).




Рис. 6. Диаграмма рассеяния при распознавании фазы сигнала

Если среднеквадратичные ошибки при интервале оцифровки в четверть периода составляют единицы процентов, то при попадании в этот интервал точек пересечения нуля (фаза – 0,  $\pi$ ,  $2\pi$ ) максимальные ошибки составляют десятки процентов. Таким образом подтверждается необходимость использования в качестве критериев оптимизации структуры ИНС не только среднеквадратичных, но и максимальных ошибок. В свою очередь, выбор количества входных нейронов зависит от целевой функции на выходе нейронной сети и интервала варьирования всех параметров сигнала.

**Выводы.** Приведенный пример последовательного выбора структуры простейшей ИНС для обработки сигналов может рассматриваться как планирование эксперимента. Оно предусматривает многократное обучение ИНС при изменении количества нейронов, скрытых слоев и оценку качества нейросетевой модели по нескольким критериям. Такой подход требует значительных вычислительных мощностей, однако современные программно-аппаратные средства предоставляют возможности его автоматизации. После обучения ИНС вычисления в элементарном персептроне с несколькими десятками нейронов, реализованные в стандартном микропроцессорном устройстве с тактовой частотой от 200 МГц, могут осуществляться за время, не превышающее единиц миллисекунд. Такое быстроедействие оказывается вполне приемлемым для обработки сигналов в электроэнергетике в реальном времени.

#### Литература

1. *Король Е.Г.* Анализ методов моделирования магнитных характеристик электромагнитов для компенсации магнитного поля электрооборудования // *Электротехника и электромеханика*. 2007. № 2. С. 31–34.
2. *Круглов В.В., Борисов В.В.* Искусственные нейронные сети. Теория и практика. М.: Горячая линия – Телеком, 2001. 382 с.
3. *Кузнецов С.Л., Нудельман Г.С.* Обеспечение правильной работы микропроцессорных устройств дифференциальной защиты при насыщении трансформаторов тока // *Электромеханика*. 2009. № 4. С. 12–17.
4. *Лямец Ю.Я., Нудельман Г.С., Павлов А.О., Ефимов Е.Б., Законьшек Я.* Распознаваемость повреждений электропередачи. Ч. 1, 2, 3 // *Электричество*. 2001. № 2. С. 16–23; № 3. С. 16–24; № 12. С. 9–22.
5. *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.
6. *Славутский А.Л.* Учет остаточной намагниченности в трансформаторе при моделировании переходных процессов // *Вестник Чувашского университета*. 2015. № 1. С. 122–130.
7. *Сучков В.О., Ядарова О.Н., Славутский Л.А.* Дистанционный ультразвуковой контроль воздушного потока на основе искусственной нейронной сети // *Вестник Чувашского университета*. 2015. № 1. С. 207–212.
8. *Basodi S., Zhang H., Pan Y.* Gradient amplification: An efficient way to train deep neural networks. *Big Data Mining and Analytics*, 2020, vol. 3(3), pp. 196–207.
9. *Bhattacharya B., Sinha A.* Intelligent Fault Analysis in Electrical Power Grids. In: *IEEE 29<sup>th</sup> International Conference on Tools with Artificial Intelligence (ICTAI)*. Boston, 2017, pp. 985–990. DOI: 10.1109/ICTAI.2017.00151.
10. *Burton B., Harley R.G.* Reducing the computational demands of continually online-trained artificial neural networks for system identification and control of fast processes. *IEEE Transactions on Industry Applications*, 1998, vol. 34(3), pp. 589–596.

11. Coury D.V., Oleskovicz M., Aggarwal R.K. An ANN routine for fault detection, classification and location in transmission lines. *Electrical Power Components and Systems*, 2002, no. 30, pp. 1137–1149.
12. 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.
13. Grossberg S. A Path Toward Explainable AI and Autonomous Adaptive Intelligence: Deep Learning, Adaptive Resonance, and Models of Perception, Emotion, and Action. *Front. Neurobot.*, 2020, vol. 14. DOI: <https://doi.org/10.3389/fnbot.2020.00036>.
14. Hassan S.R., Rehman A., Shabbir N., Unbreen A. Comparative Analysis of Power Quality Monitoring Systems. *NFC-IEFR Journal of Engineering and Scientific Research*, 2020. DOI: 10.24081/nijesr.2019.1.0004.
15. He Z., Lin S., Deng Y., Li X., Qian Q. A rough membership neural network approach for fault classification in transmission lines. *International Journal of Electrical Power and Energy Systems*, 2014, vol. 61, pp. 429–439.
16. Jain A., Thoke A.S., Patel R.N. Fault classification of double circuit transmission line using artificial neural network. *International Journal of Electrical Systems Science and Engineering, WA-SET, USA*, 2008, vol. 1, pp. 230–235.
17. Jamil M., Kalam A., Ansari A.Q., Rizwan M. Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line. *Applied Soft Computing*, 2014, vol. 19, pp. 322–332.
18. Keerthipala W.W.L., Low Tah Chong, Tham Chong Leong. Artificial neural network model for analysis of power system harmonics. *IEEE International Conference on Neural Networks*, 1995, vol. 2, pp. 905–910.
19. Kulikov A.L., Loskutov A.A., Mitrovic M. Improvement of the technical excellence of multiparameter relay protection by combining the signals of the measuring fault detectors using artificial intelligence methods. *International Scientific and Technical Conference Smart Energy Systems 2019 (SES-2019)*, 2019, vol. 124. DOI: <https://doi.org/10.1051/e3sconf/201912401039>.
20. Laruhin A., Nikandrov M., Slavutskii L. Anomalous modes recognizing secondary equipment in electric power industry: adaptive neuro algorithms. In: 2019 Int. Ural Conf. on Electrical Power Engineering: Proc. URALCON, 2019, pp. 399–403. DOI: 10.1109/URALCON.2019.8877613.
21. Mahanty R.N., Dutta Gupta P.B. Comparison of fault classification methods based on wavelet analysis and ANN. *Electric Power Components and Systems*, 2006, vol. 34, pp. 47–60.
22. Mazumdar J., Harley R.G., Lambert F., Venayagamoorthy G. Neural Network Based Method for Predicting Nonlinear Load Harmonics. *Power Electronics, IEEE Transactions*, 2007, vol. 22(3), pp. 1036–1045. DOI: 10.1109/TPEL.2007.897109.
23. Milanovic J., Ball R.F., Howe W., Preece R., Bollen M. H. J., Elphick S., Cukalevski N. International Industry Practice on Power-Quality Monitoring. *IEEE Transactions on Power Delivery*, 2014, vol. 29, pp. 934–941.
24. Montgomery D.C. Design and Analysis of Experiments. John Wiley & Sons, Inc. 1997, p. 757.
25. Niekerk C.R., Rens A.P.J., Hoffman A.J. Identification of types of distortion sources in power systems by applying neural networks. *6<sup>th</sup> IEEE Africon*, 2002, vol. 2(2), pp. 829–834.
26. Osowski S. Neural network for estimation of harmonic components in a power system. *IEEE Proceedings on Generation, Transmission and Distribution*, 1992, vol. 139(2), pp. 129–135.
27. Rosenblatt F. Principles of neurodynamics. Washington, Spartan Books, 1962.
28. Silva K.M., Souza B.A., Brito N.S.D. Fault detection and classification in transmission lines based on wavelet transform and ANN. *IEEE Transactions on Power Delivery*, 2006, vol. 21, pp. 2058–2063.
29. Soldatov A.V., Naumov V.A., Antonov V.I., Aleksandrova M.I. Information bases of algorithms for protecting a generator operating on busbars from single-phase-to-ground faults. *Investigation of the Information Bases of Algorithms Controlling Higher Current Harmonics. Power Technology and Engineering*, 2019, vol. 53(4), pp. 496–502. DOI: 10.1007/s10749-019-01105-w.
30. Sundaravaradan N. A., Surya S. Application Technique for Model-Based Approach To Estimate Fault Location. *IET Smart Grid*, 2019. DOI: 10.1049/iet-stg.2019.0135.

СЛАВУТСКИЙ ЛЕОНИД АНАТОЛЬЕВИЧ – доктор физико-математических наук, профессор кафедры автоматизации и управления в технических системах, Чувашский государственный университет, Россия, Чебоксары (lenya@slavutskii.ru; ORCID: <https://orcid.org/0000-0001-6783-2985>).

СЛАВУТСКАЯ ЕЛЕНА ВЛАДИМИРОВНА – доктор психологических наук, профессор кафедры психологии и социальной педагогики, Чувашский государственный педагогический университет имени И.Я. Яковлева, Россия, Чебоксары (slavutskayaev@gmail.com; ORCID: <https://orcid.org/0000-0002-3759-6288>).

Leonid A. SLAVUTSKII, Elena V. SLAVUTSKAYA  
CHOOSING A NEURAL NETWORK STRUCTURE  
FOR SIGNAL PROCESSING AS AN EXPERIMENT PLANNING

**Key words:** artificial neural networks, choice of neural network structure, experiment planning, signal processing in electrical engineering, neuro algorithm accuracy estimation.

The paper is devoted to the use of artificial neural networks for signal processing in electrical engineering and electric power industry. Direct propagation neural network (perceptron) is considered as an object in the theory of experiment planning. The variants of the neural network structure empirical choice, the quality criteria of its training and testing are analyzed. It is shown that the perceptron structure choice, the training sample, and the training algorithms require planning. Variables and parameters of neuro algorithm that can act as factors, state parameters, and disturbing influences in the framework of the experimental planning theory are discussed. The proposed approach is demonstrated by the example of neural network analysis of the industrial frequency signal of 50 Hz nonlinear distortions. The possibility of using an elementary perceptron with one hidden layer and a minimum number of neurons to correct the transformer saturation current is analyzed. The conditions under which the neuro algorithm allows one to restore the values of the main harmonic amplitude, frequency and phase with an error of no more than one percent are revealed. The signal processing in a "sliding window" with a duration of a fraction of the fundamental frequency period is proposed, and the neuro algorithm accuracy characteristics are estimated. The possibility to automate the neural network structure choosing for signal processing is discussed.

#### References

1. Korol E.G. *Analiz metodov modelirovaniya magnitnykh kharakteristik elektromagnitov dlya kompensatsii magnitnogo polya elektrooborudovaniya* [Analysis of methods for modeling the magnetic characteristics of electromagnets for compensating the magnetic field of electrical equipment]. *Elektrotehnika i Elektromekhanika*, 2007, no. 2, pp. 31–34.
2. Kruglov V.V., Borisov V.V. *Iskusstvennye neironnye seti. Teoriya i praktika* [Neural networks. Theory and practice] Moscow, Goryachaya liniya Telekom Publ., 2001, 382 p.
3. Kuzhekov S.L., Nudel'man G.S. *Obespecheniye pravil'noy raboty mikroprotsessornykh ustroystv differentsial'noy zashchity pri nasyshchenii transformatorov toka* [Ensuring the correct operation of microprocessor devices of differential protection during saturation of current transformers]. *Elektromekhanika*, 2009, no. 4, pp. 12–17.
4. Lyamets Yu.Ya., Nudel'man G.S., Pavlov A.O., Efimov E.B., Zakon'shek Ya. *Raspoznavаемость povrezhdenii elektroperedachi, ch. 1,2,3* [Detectability of power transmission damage]. *Elektrichestvo*, 2001, no. 2, pp. 16–23; no. 3, pp. 16–24; no. 12, pp. 9–22.
5. Slavutskaya E., Slavutskiy L. *On choosing the artificial neural networks structure and the algorithms for psycho diagnostic data analyzing* [O vybore struktury iskusstvennykh neyrosetey i algoritmov analiza psikhodiagnosticheskikh dannykh]. *Kazan pedagogical journal*, 2020, no. 5(142), pp. 202–210. DOI: 10.34772/KPJ.2020.142.5.026.
6. Slavutskiy A.L. *Accounting the residual magnetization in the transformer for the modeling of transients* [Uchet ostatochnoy namagnichennosti v transformatore pri modelirovanii perekhodnykh protsessov]. *Vestnik Chuvashskogo universiteta*, 2015, no. 1, pp. 122–130.



7. Suchkov V.O., Yadarova O.N., Slavutskii L.A. *Distantionnyi ul'trazvukovoi kontrol' vozdušnogo potoka na osnove iskusstvennoi neuronnoi seti* [Remote ultrasonic airflow control based on artificial neural network]. *Vestnik Chuvashskogo universiteta*, 2015, no. 1, pp. 207-212.

8. Basodi S., Zhang H., Pan Y. Gradient amplification: An efficient way to train deep neural networks. *Big Data Mining and Analytics*, 2020, vol. 3(3), pp. 196–207.

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

10. Burton B., Harley R.G. Reducing the computational demands of continually online-trained artificial neural networks for system identification and control of fast processes. *IEEE Transactions on Industry Applications*, 1998, vol. 34(3), pp. 589–596.

11. Coury D.V., Oleskovicz M., Aggarwal R.K. An ANN routine for fault detection, classification and location in transmission lines. *Electrical Power Components and Systems*, 2002, no. 30, pp. 1137–1149.

12. 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.

13. Grossberg S. A Path Toward Explainable AI and Autonomous Adaptive Intelligence: Deep Learning, Adaptive Resonance, and Models of Perception, Emotion, and Action. *Front. Neurobot*, 2020, vol. 14. DOI: <https://doi.org/10.3389/fnbot.2020.00036>.

14. Hassan S.R., Rehman A., Shabbir N., Unbreen A. Comparative Analysis of Power Quality Monitoring Systems. *NFC-IEFR Journal of Engineering and Scientific Research*, 2020. DOI: 10.24081/nijesr.2019.1.0004.

15. He Z., Lin S., Deng Y., Li X., Qian Q. A rough membership neural network approach for fault classification in transmission lines. *International Journal of Electrical Power and Energy Systems*, 2014, vol. 61, pp. 429–439.

16. Jain A., Thoke A.S., Patel R.N. Fault classification of double circuit transmission line using artificial neural network. *International Journal of Electrical Systems Science and Engineering, WASET, USA*, 2008, vol. 1, pp. 230–235.

17. Jamil M., Kalam A., Ansari A.Q., Rizwan M. Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line. *Applied Soft Computing*, 2014, vol. 19, pp. 322–332.

18. Keerthipala W.W.L., Low Tah Chong, Tham Chong Leong. Artificial neural network model for analysis of power system harmonics. *IEEE International Conference on Neural Networks*, 1995, vol. 2, pp. 905–910.

19. Kulikov A.L., Loskutov A.A., Mitrovic M. Improvement of the technical excellence of multiparameter relay protection by combining the signals of the measuring fault detectors using artificial intelligence methods. *International Scientific and Technical Conference Smart Energy Systems 2019 (SES-2019)*, 2019, vol. 124. DOI: <https://doi.org/10.1051/e3sconf/201912401039>.

20. Laruhin A., Nikandrov M., Slavutskii L. Anomalous modes recognizing secondary equipment in electric power industry: adaptive neuro algorithms. In: 2019 Int. Ural Conf. on Electrical Power Engineering: Proc. URALCON, 2019, pp. 399–403. DOI: 10.1109/URALCON.2019.8877613.

21. Mahanty R.N., Dutta Gupta P.B. Comparison of fault classification methods based on wavelet analysis and ANN. *Electric Power Components and Systems*, 2006, vol. 34, pp. 47–60.

22. Mazumdar J., Harley R.G., Lambert F., Venayagamoorthy G. Neural Network Based Method for Predicting Nonlinear Load Harmonics. *Power Electronics, IEEE Transactions*, 2007, vol. 22(3), pp. 1036–1045. DOI: 10.1109/TPEL.2007.897109.

23. Milanovic J., Ball R.F., Howe W., Preece R., Bollen M. H. J., Elphick S., Cukalevski N. International Industry Practice on Power-Quality Monitoring. *IEEE Transactions on Power Delivery*, 2014, vol. 29, pp. 934–941.

24. Montgomery D.C. Design and Analysis of Experiments. John Wiley & Sons, Inc. 1997, p. 757.

25. Niekerk C.R., Rens A.P.J., Hoffman A.J. Identification of types of distortion sources in power systems by applying neural networks. *6<sup>th</sup> IEEE Africon*, 2002, vol. 2(2), pp. 829–834.

26. Osowski S. Neural network for estimation of harmonic components in a power system. *IEEE Proceedings on Generation, Transmission and Distribution*, 1992, vol. 139(2), pp. 129–135.
27. Rosenblatt F. Principles of neurodynamics. Washington, Spartan Books, 1962.
28. Silva K.M., Souza B.A., Brito N.S.D. Fault detection and classification in transmission lines based on wavelet transform and ANN. *IEEE Transactions on Power Delivery*, 2006, vol. 21, pp. 2058–2063.
29. Soldatov A.V., Naumov V.A., Antonov V.I., Aleksandrova M.I. Information bases of algorithms for protecting a generator operating on busbars from single-phase-to-ground Faults. *Investigation of the Information Bases of Algorithms Controlling Higher Current Harmonics. Power Technology and Engineering*, 2019, vol. 53(4), pp. 496–502. DOI: 10.1007/s10749-019-01105-w.
30. Sundaravaradan N. A., Surya S. Application Technique For Model-Based Approach To Estimate Fault Location. *IET Smart Grid*, 2019. DOI: 10.1049/iet-stg.2019.0135.

---

**LEONID A. SLAVUTSKII – Doctor of Physical and Mathematical Sciences, Professor, Department of Automation and Control in Technical Systems, Chuvash State University, Russia, Cheboksary (lenya@slavutskii.ru; ORCID: <https://orcid.org/0000-0001-6783-2985>).**

**ELENA V. SLAVUTSKAYA – Doctor of Psychological Sciences, Professor, Department of Psychology and Social Pedagogy, I.Ya. Yakovlev Chuvash State Pedagogical University, Russia, Cheboksary (slavutskayaev@gmail.com; ORCID: <https://orcid.org/0000-0002-3759-6288>).**

---

**Формат цитирования:** *Славутский Л.А., Славутская Е.В.* Выбор структуры нейронной сети для обработки сигналов как планирование эксперимента // Вестник Чувашского университета. – 2021. – № 3. – С. 123–132. DOI: 10.47026/1810-1909-2021-3-123-132.