

УДК 621.316.925

ББК 31.211

Ю.А. ДЕМЕНТИЙ, А.Н. МАСЛОВ

## НЕЙРОСЕТЕВОЙ КЛАССИФИКАТОР РЕЖИМОВ РАБОТЫ ЭНЕРГООБЪЕКТА И ОЦЕНКА ЕГО РАСПОЗНАЮЩЕЙ СПОСОБНОСТИ ПРИ РАЗЛИЧНОМ КОЛИЧЕСТВЕ ПРЕЦЕДЕНТОВ

**Ключевые слова:** машинное обучение, нейронная сеть, классификация режимов работы объекта, распознающая способность.

Классические алгоритмы построения релейной защиты не используют всю доступную информационную базу и, соответственно, не могут обеспечить максимально возможную чувствительность при гарантированной селективности. Эти алгоритмы, как правило, концентрируют различную информацию, в результате чего она частично теряется. К примеру, реле сопротивления оперирует комплексным сопротивлением, т.е. двумя вещественными параметрами, хотя для расчёта комплексного сопротивления используются две комплексные переменные – напряжение и ток. В статье показано решение задачи классификации режимов работы линии электропередачи с использованием нейросетевого алгоритма. Универсальным классификатором является простейшая нейронная сеть – перцептрон, так как для него доказана теорема о сходимости, показывающая, что если классификация существует, то перцептрон достаточной сложности способен её описать. Обсуждаются статистическая и геометрическая интерпретации различных алгоритмов. Показана зависимость качества работы классификатора от структуры и параметров нейронной сети, а также от распределения прецедентов в обучающей выборке, на основании которых производится обучение. Оценивается распознающая способность нейросетевого классификатора, т.е. способность отличать короткие замыкания в пределах защищаемой зоны от коротких замыканий за пределами защищаемой зоны при различном количестве прецедентов в обучающей выборке. Показаны пределы применимости подобных алгоритмов для задачи классификации режимов работы объекта в электроэнергетике и сформулированы рекомендации для их практического применения. Полученные результаты свидетельствуют о необходимости разработки методов обучения классификаторов, в основу которых положен источник информативных прецедентов в виде имитационной модели объекта.

Построение любого алгоритма релейной защиты преследует цель обеспечения селективности. В то же время необходимо достигнуть достаточной распознающей способности. Для всех широко применяемых алгоритмов релейной защиты существуют руководящие указания по расчёту уставок. Эти методики позволяют выбрать параметры срабатывания защит на основе информации о структуре и параметрах защищаемого объекта. Как правило, такие защиты не используют всю доступную информационную базу и, соответственно, не могут обеспечить максимально возможную чувствительность при гарантированной селективности. Исследование применимости нейросетевых алгоритмов в электроэнергетике является актуальной задачей [3, 4].

Актуальность настоящей статьи заключается в использовании нейросетевых классификаторов для обхода ограничений по чувствительности у классических алгоритмов.

Целью работы являются построение нейросетевого классификатора режимов работы энергообъекта и последующая оценка его распознающей способности.

Известно, что при достаточном количестве информативных прецедентов нейросетевой классификатор способен обеспечить абсолютную селективность, обеспечив при этом максимальную чувствительность [2].

**Нейросетевая классификация режимов.** Универсальным классификатором является простейшая нейронная сеть – перцептрон, так как для него доказана теорема о сходимости, показывающая, что если классификация существует, то перцептрон достаточной сложности способен её описать [7]. По своей сути перцептрон является простейшей нейронной сетью, но тем не менее представляет собой "чёрный ящик", что ограничивает его применение в технике и в то же время обуславливает необходимость подробного анализа ограничений этой применимости.

Нейронные сети способны классифицировать режимы работы энергообъекта, однако в данный момент неясно, как выполнить обучение нейронной сети, используя ту же информацию, которая доступна для расчёта параметров классических алгоритмов. Для обучения нейронной сети, т.е. в общем случае для решения многопараметрической задачи нелинейной оптимизации, используются наборы данных, представляющие собой пары векторов входных данных и идентификаторов класса. Применительно к задаче классификации режимов работы энергообъекта в роли таких данных выступают токи и напряжения, наблюдаемые в месте установки защиты, для которых точно известно, относится ли наблюдаемый режим к повреждению защищаемого участка или к повреждению смежного.

**Имитационная модель линии.** Для генерации прецедентов использовалась математическая модель линии с двухсторонним питанием, изображённая на рис. 1. Имитационная модель выступает в роли источника информации о токе и напряжении в месте наблюдения. Токи и напряжения используются для расчёта сопротивления  $Z$  на зажимах реле. Пара  $Z$  и информация о принадлежности данного режима к внешнему или внутреннему короткому замыканию образует прецедент. Множество различных значений сопротивления, принадлежащих только к внутренним КЗ или только к внешним, образует класс.

Фиксированные параметры модели приведены в табл. 1, варьируемые параметры – в табл. 2. Варьируемые параметры генерируются с использованием генератора псевдослучайных чисел. Угол передачи линии  $\delta$  и расстояние до места повреждения  $x_f$  распределены равномерно, так как все значения в пределах диапазона варьирования принимаются равновероятными. Величина переходного сопротивления в месте повреждения  $R_f$  распределена логарифмически равномерно из предположения, что наиболее часто возникают короткие замыкания через сравнительно небольшие переходные сопротивления.

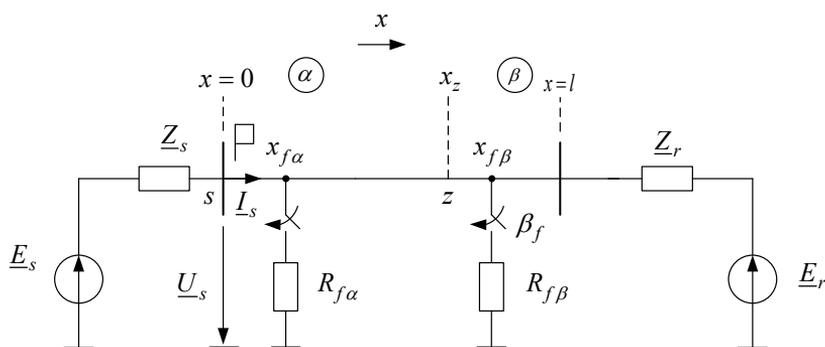


Рис. 1. Имитационная модель линии

Таблица 1

**Фиксированные параметры модели**

Параметр	Значение
$U_{ном}$	110 кВ
$l$	100 км
$Z^0$	$0,1+j0,4$ Ом/км
$Z_s$	$1+j10$ Ом
$Z_r$	$5+j50$ Ом

Таблица 2

**Варьируемые параметры модели**

Параметр	Диапазон значений
$\delta$	$-30^\circ \dots 30^\circ$
$x_{f\alpha}$	$0 \dots 80$ км
$x_{f\beta}$	$80 \dots 100$ км
$R_f$	$0 \dots 50$ Ом

**Обучение на прецедентах.** Пусть имеется линия с двухсторонним питанием, на которой в течение долгого промежутка времени фиксировались значения токов и напряжений в режимах короткого замыкания. Кроме того, отмечалось, к какому классу относится каждый режим – внешнее или внутреннее короткое замыкание. Эти данные генерировались с помощью математической модели такой линии, для которой все параметры принимались фиксированными, а варьировались лишь угол передачи линии  $\delta$ , расстояние до места повреждения  $x_f$ , а также величина переходного сопротивления в месте повреждения  $R_f$ . Угол передачи линии, а также место повреждения распределены равномерно. Величина переходного сопротивления распределена логарифмически равномерно исходя из предположения, что наиболее часто возникают короткие замыкания через сравнительно небольшие переходные сопротивления.

Простейшим примером, для которого известны аналитические выражения, определяющие истинную границу области, в пределах которой отображаются все короткие замыкания вне защищаемой зоны, является комплексная плоскость замера сопротивления  $Z$  [6]. На данной плоскости красными точками показаны прецеденты, соответствующие коротким замыканиям в пределах защищаемого участка, синими точками – вне защищаемого участка (рис. 2). Зелёная линия показывает истинную границу, в пределах которой могут находиться все теоретически возможные прецеденты, соответствующие внешним коротким замыканиям для рассматриваемой модели линии.

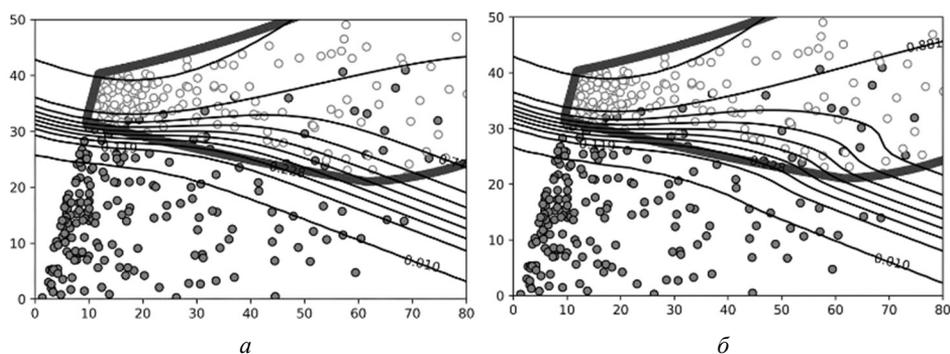


Рис. 2. Отображение прецедентов и граничной линии на комплексной плоскости:  
*a* – изолинии для нейронной сети с 15 нейронами в скрытом слое;  
*б* – изолинии для нейронной сети с 30 нейронами в скрытом слое

Алгоритм генерации прецедентов был записан на языке программирования Python, нейронная сеть была сформирована на основе библиотеки Scikit-learn [8]. Полученные данные (по 200 прецедентов для каждого класса) используются для обучения нейронной сети. Выходной величиной нейронной сети является вероятность  $p$  принадлежности прецедента к первому или второму классу [5]:

$$p = f \left( \sum_{i=1}^n x_i w_i \right),$$

где  $x_i$  – значение  $i$ -го входа нейрона;  $w_i$  – вес  $i$ -й связи;  $n$  – число входов нейрона;  $f$  – функция активации (в данном примере используется сигмоида).

Для того, чтобы нейронная сеть работала как классификатор режимов, необходимо определить пороговое значение, которое выбирается исходя из требования селективности релейной защиты. Значение вероятности на выходе нейронной сети выше этого порога будет означать принадлежность режима к первому классу, вероятность ниже порога – ко второму. На той же комплексной плоскости  $\underline{Z}$  показаны изолинии, каждая из которых будет соответствовать определённой вероятности. При обучении на прецедентах селективность защиты оценивается с помощью метрики полноты классификации имеющихся прецедентов.

В идеальном случае изолиния совпадает с истинной границей (зелёная линия). Как видно из рис. 3, вне зависимости от сложности нейронной сети, при обучении на ограниченном числе прецедентов нет возможности выбрать порог так, чтобы это обеспечивало наибольшую чувствительность и при этом гарантировало селективность. Можно заметить, что даже если изолиния расположена близко к истинной границе в области, где количество прецедентов значительное, то в правой части рисунка изолиния не загибается вверх и сильно отклоняется от истинной границы, что отрицательно сказывается на чувствительности. В случае слишком простой нейронной сети изолинии, расположенные близко к истинной границе, практически вырождаются в прямую линию, а в случае слишком сложной начинают излишне ориентироваться на отдельно

расположенные прецеденты. Таким образом, все имеющиеся изолинии не подходят либо по условию селективности, либо излишне перестраховываются и тем самым не обеспечивают максимальную чувствительность.

Если имеется гораздо более объёмная и информативная база прецедентов (в данном примере по 5000 для каждого класса), то появляется возможность выбрать порог так, чтобы соответствующая изолиния совпадала с истинной границей, в пределах которой на комплексной плоскости отображаются внешние короткие замыкания (рис. 3).

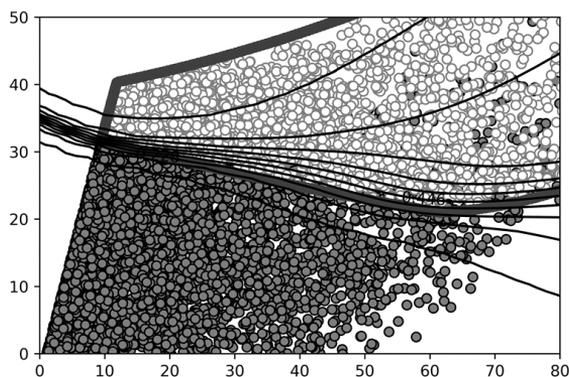


Рис. 3. Изолинии нейронной сети (15 нейронов в скрытом слое) при большом объеме информационной базы

**Оценка распознающей способности.** Распознающая способность классификатора оценивается по отложенной выборке прецедентов (10 000 режимов каждого класса) [4]. Порог срабатывания классификатора выбирается таким образом, чтобы все прецеденты, относящиеся к внешним коротким замыканиям, распознавались классификатором верно. Таким образом, класс, соответствующий внешним коротким замыканиям, устанавливается в качестве приоритетного. Обучение классификатора осуществляется 1000 раз для  $N$  прецедентов каждого класса, где  $N$  принимает значения от 1 до 1500. При этом для каждого случая обучения генерируются новые прецеденты.

На рис. 4 на оси абсцисс отложено количество прецедентов в обучающей выборке, а по оси ординат отложен доверительный интервал для доли режимов, которую удаётся распознать (рис. 4, *a*), и средневзвешенное переходное сопротивление в месте повреждения для распознанных КЗ (рис. 4). Доля режимов, которую удаётся распознать, рассчитывается как отношение количества распознанных прецедентов, относящихся к повреждению в пределах защищаемой зоны, к общему количеству прецедентов, относящихся к коротким замыканиям в защищаемой зоне. Средневзвешенное переходное сопротивление рассчитывается как отношение суммы величин переходных сопротивлений распознанных повреждений к количеству распознанных прецедентов в защищаемой зоне.

По отложенной выборке определяется эталонное значение доли режимов, которую удаётся распознать при использовании в качестве замера комплекс-

ного сопротивления на зажимах реле, а также эталонное значение средневзвешенного сопротивления.

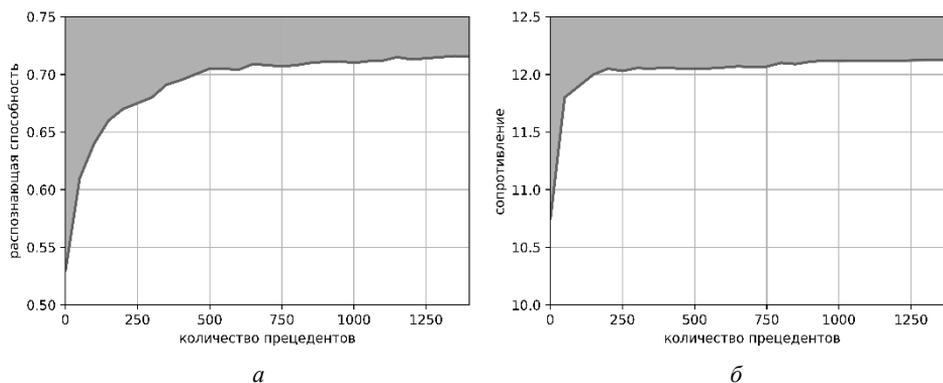


Рис. 4. Зависимости от количества прецедентов в обучающей выборке: а – доли распознанных режимов; б – средневзвешенного сопротивления

Из рис. 4 видно, что при увеличении числа прецедентов, генерируемых согласно описанному распределению, графики стремятся к эталонным значениям.

Представленные результаты не соответствуют физическому пределу распознаваемости, так как получены с использованием прецедентного подхода к обучению, не позволяющему контролировать информативность обучающей выборки [1].

**Выводы.** Результаты, приведённые для рассматриваемого объекта, являются наилучшими из всех возможных, так как получены для заведомо известного порога срабатывания, обеспечивающего селективность. Показано, что обучение на прецедентах в общем случае не позволяет решить задачу классификации рассматриваемых режимов, обеспечивая наивысшую чувствительность при гарантированной селективности. Решение может быть достигнуто лишь при наличии достаточно информативной информационной базы, что не может быть достигнуто в реальных условиях. Прецедентный подход не позволяет построить защиту для вновь сооружаемых объектов, так как для них вовсе отсутствуют прецеденты. Это обуславливает необходимость разработки методов обучения классификаторов на основании имитационной модели в качестве источника информативных прецедентов.

#### Литература

1. Дементий Ю.А., Активное обучение классификатора режимов работы объекта с использованием имитационной модели // Современные тенденции развития цифровых систем релейной защиты и автоматики: материалы науч.-техн. конф. молодых специалистов форума «РЕЛАВЭКСПО-2021». Чебоксары: Изд-во Чуваш. ун-та, 2021. С. 157–162.

2. Дементий Ю.А., Маслов А.Н., Николаев К.П. Нейросетевая классификация режимов // Современные тенденции развития цифровых систем релейной защиты и автоматики: материалы науч.-техн. конф. молодых специалистов форума «РЕЛАВЭКСПО-2021». Чебоксары: Изд-во Чуваш. ун-та, 2021. С. 147–152.

3. Коцеев М.И., Славутский А.Л., Славутский Л.А. Элементарный перцептрон как инструмент анализа переходных процессов // Вестник Чувашского университета. 2020. № 3. С. 84–93.
4. Коцеев М.И., Славутский А.Л., Славутский Л.А. Простые нейросетевые алгоритмы для волнового метода определения места повреждения электросети // Вестник Чувашского университета. 2019. № 3. С. 110–118.
5. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. М.: Горячая линия – Телеком, 2001. 382 с.
6. Мартынов М.В. Исследование и разработка обучаемых модулей микропроцессорных защит линий электропередачи: автореф. дис. ... канд. техн. наук. Чебоксары, 2014. 24 с.
7. Haykin S. Neural Networks: A Comprehensive Foundation Subsequent Edition. Prentice Hall PTR, Upper Saddle River, NJ, United States, 1998, 842 p.
8. Scikit-learn: Machine Learning in Python, Pedregosa et al., JMLR 12, 2011, pp. 2825–2830.

---

ДЕМЕНТИЙ ЮРИЙ АНАТОЛЬЕВИЧ – кандидат технических наук, руководитель группы, ООО «Релематика», Россия, Чебоксары (dementiy.yu.a@gmail.com).

МАСЛОВ АЛЕКСАНДР НИКОЛАЕВИЧ – кандидат технических наук, заведующий сектором, ООО «Релематика» (maslov\_an@relematika.ru).

---

Yuri A. DEMEN TIY, Aleksandr N. MASLOV

**NEURAL NETWORK CLASSIFIER OF ENERGY FACILITIES OPERATING MODES AND ITS RECOGNITION ABILITY ASSESSMENT AT DIFFERENT NUMBER OF PRECEDENTS**

**Key words:** machine learning, neural network, classification of object operation modes, recognizing ability.

*Classical algorithms of relay protection construction do not use all available information base and therefore cannot provide the highest possible sensitivity with guaranteed selectivity. These algorithms, as a rule, concentrate different information, as a result of which it is partially lost. For example, the resistance relay operates with complex resistance, that is, two real parameters, although two complex variables – voltage and current – are used to calculate the complex resistance. This paper shows the solution to the problem of classification of power line operating modes using a neural network algorithm. The simplest neural network, a perceptron, is a universal classifier, since a convergence theorem has been proved for it, showing that if a classification exists, a perceptron of sufficient complexity is able to describe it. The statistical and geometrical interpretations of various algorithms are discussed. The dependence of the quality of the classifier's work on the distribution of precedents in the training sample, on which the training is based, as well as on the structure and parameters of the neural network, is shown. The recognition ability of the neural network classifier, i.e. the ability to distinguish short circuits within the protected zone from short circuits outside the protected zone at different number of precedents in the training sample, is evaluated. The limits of applicability of such algorithms to the task of classification of object operation modes in electric power industry are shown and recommendations for their practical application are formulated. The results obtained indicate the need to develop methods for training classifiers that are based on a source of informative precedents in the form of a simulation model of the object.*

References

1. Dementiy Yu.A. Aktivnoe obuchenie klassifikatora rezhimov raboty ob"ekta s ispol'zovaniem imitacionnoj modeli [Active training classifier operating modes of an object using a simulation model]. In: *Sovremennye tendentsii razvitiya tsifrovyykh sistem releinoi zashchity i avtomatiki: materialy nauch.-tekhn. konf. molodykh spetsialistov foruma «RELA VEK SPO-2021»* [Proc. of Sci. Conf. «Modern trends in the development of digital relay protection and automation systems»]. Cheboksary, Chuvash State University Publ, 2021, pp. 157–162.

2. Dementiy Yu.A., Maslov A.N., Nikolaev K.P. *Neirosetevaya klassifikatsiya rezhimov* [Neural classification of modes]. In: *Sovremennye tendentsii razvitiya tsifrovyykh sistem releinoi zashchity i avtomatiki: materialy nauch.-tekhn. konf. molodykh spetsialistov foruma «RELAVEKSPO-2021»* [Proc. of Sci. Conf. «Modern trends in the development of digital relay protection and automation systems»]. Cheboksary, Chuvash State University Publ, 2021, pp. 147–152.

3. Haykin S. *Neural Networks: A Comprehensive Foundation* Subsequent Edition. New York, Prentice Hall PTR, 1998, 842 p.

4. Kosheev M.I., Slavutskii A.L., Slavutskii L.A. *Elementarnyi perseptron kak instrument analiza perekhodnykh protsessov* [Elementary perceptron as a tool for the transients analyzing]. *Vestnik Chuvashskogo Universiteta*, 2020, no. 3, pp. 84–93.

5. Koshcheev M.I., Slavutskii A.L., Slavutskii L.A. *Prostyie neyrosetevyye algoritmy dlya volnovoogo metoda opredeleniya mesta povrezhdeniya elektroseti* [Simple neural network algorithms for the wave method of fault location in power networks]. *Vestnik Chuvashskogo Universiteta*, 2019, no. 3, pp. 110–118.

6. 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.

7. Martynov M.V. *Issledovanie i razrabotka obuchaemykh modulei mikroprotsessornykh zashchit linii elektroperedachi: avtoref. dis. ... cand. techn. nauk* [Research and development of trainable modules for microprocessor protection of power lines: Abstract of the Cand. Diss.]. Cheboksary, 2014, 24 p.

8. Scikit-learn: Machine Learning in Python, Pedregosa *et al.*, *JMLR* 12, 2011, pp. 2825–2830.

---

**YURI A. DEMENTIY – Candidate of Technical Sciences, Head of the Group, Relematika LLC, Russia, Cheboksary (dementiy.yu.a@gmail.com).**

**ALEKSANDR N. MASLOV – Candidate of Technical Sciences, Head of Sector, Relematika LLC, Russia, Cheboksary (maslov\_an@relematika.ru).**

---

**Формат цитирования:** Дементий Ю.А., Маслов А.Н. Нейросетевой классификатор режимов работы энергообъекта и оценка его распознающей способности при различном количестве прецедентов // Вестник Чувашского университета. – 2021. – № 3. – С. 45–52. DOI: 10.47026/1810-1909-2021-3-45-52.