

ЭНЕРГЕТИКА



Научная статья

УДК 621.311

<https://doi.org/10.21285/1814-3520-2022-2-197-216>

Разработка метода определения гибкости электроэнергетической системы с ветропарками на базе искусственных нейронных сетей

Елена Сергеевна Аксаева^{1✉}, Анна Михайловна Глазунова²^{1,2} Институт систем энергетики им. Л.А. Мелентьева СО РАН, г. Иркутск, Россия¹ aksaeva@isem.irk.ru, <https://orcid.org/0000-0002-6819-7474>² glazunova@isem.irk.ru, <https://orcid.org/0000-0002-7288-6168>

Резюме. Цель исследования – представление метода определения гибкости электроэнергетической системы в режиме онлайн с помощью искусственных нейронных сетей разных структур. Для быстрого вычисления показателя гибкости электроэнергетической системы используется разработанный алгоритм, в который встроена искусственная нейронная сеть с разными парадигмами обучения. Приемлемое время получения результатов обеспечивается разделением процесса вычисления гибкости на процессы, выполняемые офлайн и онлайн. Для обучения нейронных сетей были использованы методы обучения искусственных нейронных сетей. Многослойный персептрон обучается методом обратного распространения ошибки. Обучение нейронной сети Кохонена выполняется по правилу «победитель забирает все». В качестве меры близости между исследуемыми векторами используется Евклидово расстояние. Разработан алгоритм анализа результатов двух типов искусственных нейронных сетей с разными структурами на предмет выбора оптимальной структуры каждого типа нейронной сети, с точки зрения рекомендации к их применению в режиме реального времени, при определении гибкости электроэнергетической системы. Апробация предложенного алгоритма была выполнена на 6-узловой схеме по сценарию: вычислить гибкость данной системы, функционирующей в разных режимах. Анализ критерия показал, что структура многослойного персептрона с 16 нейронами в скрытом слое и структура нейронной сети Кохонена с девятью выходными нейронами являются оптимальными для определения установившегося режима с минимальной гибкостью в режиме реального времени. Анализ результатов показал, что величина гибкости системы не остается постоянной в разное время суток. Искусственные нейронные сети могут быть применены при определении гибкости электроэнергетической системы в режиме реального времени.

Ключевые слова: гибкость, электроэнергетические системы, искусственные нейронные сети, онлайн, установившийся режим, управление

Благодарности: Работа выполнена в рамках проекта государственного задания (№ FWEU-2021-0001) программы фундаментальных исследований РФ на 2021–2030 гг.

Для цитирования: Аксаева Е. С., Глазунова А. М. Разработка метода определения гибкости электроэнергетической системы с ветропарками на базе искусственных нейронных сетей // iPolytech Journal. 2022. Т. 26. № 2. С. 197–216. <https://doi.org/10.21285/1814-3520-2022-2-197-216>.

ENERGY INDUSTRY

Original article

Development of an artificial neural network-based method for determining the flexibility of power systems with high share of wind generation

Elena S. Aksaeva^{1✉}, Anna M. Glazunova²^{1,2} Melentiev Energy Systems Institute of Siberian Branch of Russian Academy of Sciences, Irkutsk, Russia¹ aksaeva@isem.irk.ru, <https://orcid.org/0000-0002-6819-7474>² glazunova@isem.irk.ru, <https://orcid.org/0000-0002-7288-6168>

© Аксаева Е. С., Глазунова А. М., 2022

<https://ipolytech.ru>

Abstract. A method for the online determination of the resilience of an electric power system using artificial neural networks having various structures is presented. A developed algorithm comprised of an artificial neural network with multiple learning paradigms is used for the rapid calculation of the adaptability index of the electric power system. A satisfactory time for obtaining results is ensured by dividing the adaptability calculation into offline and online processes. To train the neural networks, various methods were used. The multilayer perceptron was trained using the method of backward propagation of error, while training of the Kohonen neural network was performed based on the winner-take-all rule. Euclidean distance was used as a proximity measure between the studied vectors. An algorithm for analysing the results obtained by two types of artificial neural networks having dissimilar structures was developed in order to select their optimal structure and recommend a neural network for the real-time determination of the resilience of an electric power system. The proposed algorithm was validated on a 6-node scheme following the command script: computing the resilience of a given system, functioning in multiple modes. The criterion analysis showed that the structures of multilayer perceptron having 16 neurons in a hidden layer and Kohonen neural network having 9 output neurons represent the optimal solution for determining the steady-state mode at the minimum resilience in real-time. According to the results, the value of the resilience of the system varies over the course of a day. The possibility of using artificial neural networks for determining the resilience of electric power systems in real-time is demonstrated.

Keywords: flexibility, electric power systems, artificial neural networks, online, steady state, control

Acknowledgements: The research was carried out under the State Assignment Project (no. FWEU-2021-0001) of the Fundamental Research Program of the Russian Federation 2021-2030.

For citation: Aksaeva E. S., Glazunova A. M. Development of an artificial neural network-based method for determining the flexibility of power systems with high share of wind generation. *iPolytech Journal*. 2022;26(2):197-216. (In Russ.). <https://doi.org/10.21285/1814-3520-2022-2-197-216>.

ВВЕДЕНИЕ

В последние годы в результате внедрения в электроэнергетические системы (ЭЭС) возобновляемых источников энергии наблюдается растущий интерес к средствам обеспечения и мониторинга гибкости данных систем. Гибкостью ЭЭС в данной работе называется их способность сохранять баланс мощности в течение заданного времени без ввода в работу аварийных резервов. Для обеспечения гибкости необходимы резервы мощности, в качестве которых используются разные средства [1]. Авторы [2] представили информацию о видах оперативных резервов, имеющихся в США и Европе. Авторы³ описали методику, в соответствии с которой определяются минимально необходимые объемы резервов активной мощности ЭЭС России. В дополнение к резервам, имеющимся на стороне генерации, в качестве средств гибкости рассматриваются механизмы управления активными потребителями [3, 4], объединение ЭЭС [5], создание мультиэнергетических систем [6], использование разных видов накопителей энергии. Авторы [7] предложили структуру характеристики гибкости. Значение гибкости является индикатором, который может использоваться системным оператором

для сравнения его с затратами различных активных элементов, обеспечивающих услуги гибкости.

С целью оптимального управления режимами ЭЭС задачи, связанные с мониторингом гибкости ЭЭС, решаются в режиме реального времени. Основными требованиями, предъявляемыми к задачам онлайн, являются корректность результатов и быстрота вычислений. Для получения корректных результатов необходимо обрабатывать большой объем данных. Для получения быстрых ответов имеющийся объем данных необходимо обработать за короткий промежуток времени. Удовлетворение этих требований возможно за счет применения искусственных нейронных сетей (ИНС) при решении задачи определения гибкости ЭЭС.

В настоящее время существует ряд работ, посвященных определению гибкости ЭЭС с помощью ИНС. В работе [8] изложена теоретическая база для количественной оценки потенциала гибкости сети на основе машинного обучения. ИНС используются для классификации ретроспективных данных о нагрузках нескольких подстанций сети. Полученные метамоделли отдельных узлов могут быть использованы для уменьшения трудно-

³ОАО «СО ЕЭС». Методика определения минимально необходимых объемов резервов активной мощности ЕЭС России [Электронный ресурс]. URL: https://so-eps.ru/fileadmin/files/company/markets/2014/metodika_opredelenija_1114.pdf. (23.10.2021).

стей, связанных с идентификацией источников, обладающих небольшим запасом гибкости. Приведение в действие множества таких источников улучшит гибкость системы. В работе [9] авторы предложили подход к представлению и передаче информации об энергетической гибкости распределенных энергоресурсов с помощью суррогатных моделей на основе искусственных нейронных сетей. Представленный подход позволяет обмениваться общей и в то же время подробной информацией о гибкости любых распределенных энергоресурсов. В статье [10] представлены обобщенные схемы моделирования гибкости распределенных энергоресурсов и оценена идея применения ИНС в предложенных схемах. В работе [11] для повышения информации о гибкости электрических сетей при наличии возобновляемых источников энергии разрабатывалась обучающаяся модель на основе нейронных сетей. С этой целью изучались способности всех известных нейронных сетей обучаться на потоковых данных. В результате предложен метод, основанный на ансамбле нейронных сетей, для улучшения характеристик обобщения за счет возможностей использования разных сочетаний исследуемых ИНС. Авторы статьи [12] предложили подход «черного ящика» для исследования гибкости виртуальной электростанции с использованием методов машинного обучения. Наличие точной информации о гибкости способствует уменьшению небалансов в системе, что сокращает финансовые штрафы. В статье приведены результаты исследований и сравнение двух методов машинного обучения: многомерная линейная регрессия и однослойная искусственная нейронная сеть. Сравнительный анализ полученных результатов показал, что алгоритм линейной регрессии в среднем способен оценить гибкость с ошибкой 15%, алгоритм с однослойной ИНС оценивает гибкость с ошибкой 5,3%. Это означает, что применение ИНС для оценки гибкости ЭЭС является более целесообразным. Авторы статьи [13] предлагают усовершенствованный механизм согласования спроса и предложения в энергосетях, в которых существует неопределенность, связанная с возобновляемыми источ-

никами энергии и новыми видами потребления нагрузки. Предлагаемый механизм основан на использовании мультиагентных систем и искусственных нейронных сетей и предназначен для исследования и определения гибкости распределенных энергетических ресурсов. На основе полученной информации вырабатываются управляющие воздействия, выполнение которых требуется для компенсации возникающих неопределенностей. Авторы [14] разработали метод интегрирования искусственной нейронной сети в систему централизованного холодоснабжения, целью которого является уменьшение потребления электроэнергии за счет выявления и использования энергетической гибкости. Нейронная сеть обучается оценивать величину мощности, которая требуется каждому конкретному пользователю для процесса охлаждения. Для того чтобы оптимизировать использование ресурсов системы и гибкость возобновляемых источников энергии, авторы статьи [15] предлагают определять изменяющиеся во времени нагрузки путем объединения методов идентификации системы и нелинейной численной оптимизации. Параметры идентификационной модели связываются с данными измерений с помощью искусственных нейронных сетей, что позволяет создавать аналогичную динамику без использования методов численной оптимизации.

Целью данного исследования является представление метода определения гибкости ЭЭС в режиме онлайн с помощью ИНС. Для достижения этой цели был разработан алгоритм анализа результатов двух типов ИНС с разными структурами на предмет выбора оптимальной структуры каждого типа с точки зрения рекомендации к их применению в режиме реального времени при определении гибкости ЭЭС.

ВЫЧИСЛЕНИЕ ГИБКОСТИ ЭЛЕКТРОЭНЕРГЕТИЧЕСКОЙ СИСТЕМЫ

Для определения того, является ли ЭЭС гибкой, анализируется следующее условие:

$$F_R = R, \quad (1)$$

где F_R – величина, показывающая значение небаланса в ЭЭС, для компенсации которого с целью сохранения баланса мощности в ней не требуется ввод аварийных резервов в указанный период времени. Величина F_R вычисляется при определенном распределении генерирующих мощностей, поэтому при анализе (1) учитывается сочетание существующих небалансов. Выполнение условия (1) означает, что ЭЭС обладает гибкостью. Значение F_R вычисляется следующим образом:

$$F_R = \sum_{i=1}^R F_i; \quad (2)$$

$$P_i^{ypmin} - P_i > 0, \text{ то } F_i = 1, \text{ иначе } F_i = 0, \quad (3)$$

где P_i^{ypmin} – активная мощность в i -м узле с неопределенностью в УР с минимальной гибкостью; P_i – активная мощность в узле i в исследуемом режиме; R – количество нагрузочных узлов. Понятие «установившийся режим» (УР) с минимальной гибкостью (далее УР с минимальной гибкостью) введено в [16]. Наступление данного режима в ЭЭС означает, что при имеющемся распределении генерирующих мощностей увеличение нагрузки хотя бы в одном из узлов приведет к дефициту мощности или к использованию аварийных резервов. Последнее недопустимо по причине нарушения безопасности работы ЭЭС.

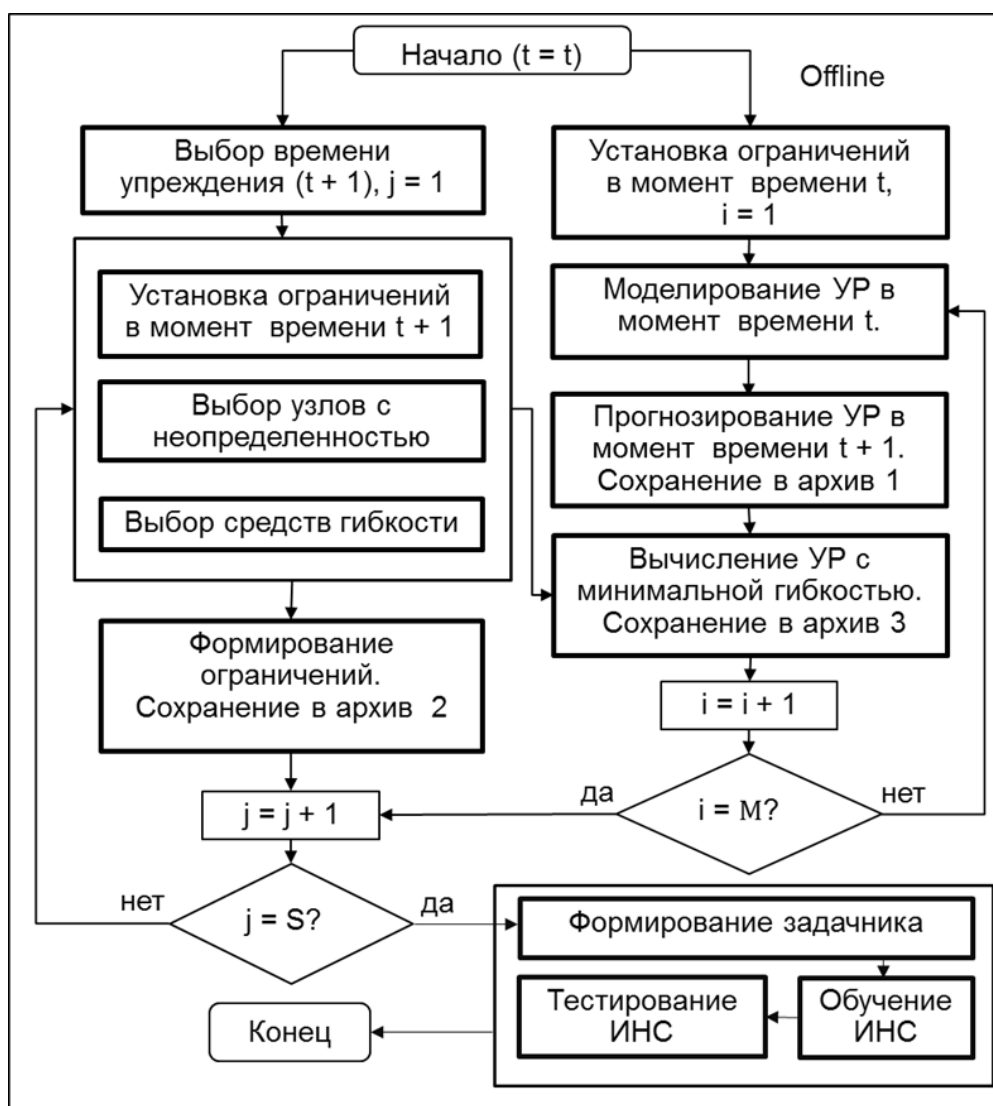


Рис. 1. Алгоритм формирования окружения искусственной нейронной сети. Офлайн (S – количество примеров в архиве 2, M – количество примеров в архиве 1)

Fig. 1. Formation algorithm of artificial neural network environment. Offline (S – the number of examples in archive 2, M – the number of examples in archive 1)

Для определения количественного показателя гибкости, которой обладает ЭЭС, применяется следующее выражение:

$$F_f = \sum_{i=1}^R (P_i^{ypmin} - P_i). \quad (4)$$

Вследствие зависимости величины гибкости ЭЭС от факторов, которые меняются достаточно часто, а иногда неожиданно, необходимо уточнять показатель гибкости в режиме онлайн. Одним из обязательных требований при решении задач онлайн является неперевышение времени, отведенного для получения результатов.

Для быстрого вычисления показателя гибкости ЭЭС предлагается алгоритм, в который встроена ИНС с парадигмой обучения без учителя [17] или с парадигмой обучения с учителем [18]. ИНС в этом алгоритме ответственна за определение параметров УР с минимальной гибкостью. Разделение про-

цесса вычисления гибкости на процессы, выполняемые офлайн (рис. 1) и онлайн (рис. 2), обеспечивает приемлемое время получения результатов.

В режиме офлайн формируется окружение или среда, в которой ИНС будут функционировать. На рис. 1 показан алгоритм моделирования УР в момент времени t , моделирования архивов УР в момент времени $t + 1$ (архив 1), ограничений (архив 2) и УР с минимальной гибкостью (архив 3). УР в момент времени $t + 1$ называется исследуемым режимом (архив 1). Из данных этих архивов создаются обучающие и тестовые выборки для обучения и тестирования ИНС.

На рис. 2 представлена укрупненная схема вычисления гибкости ЭЭС онлайн. Схема состоит из блока с исходной информацией и алгоритма, представляющего собой последовательное выполнение следующих шагов.

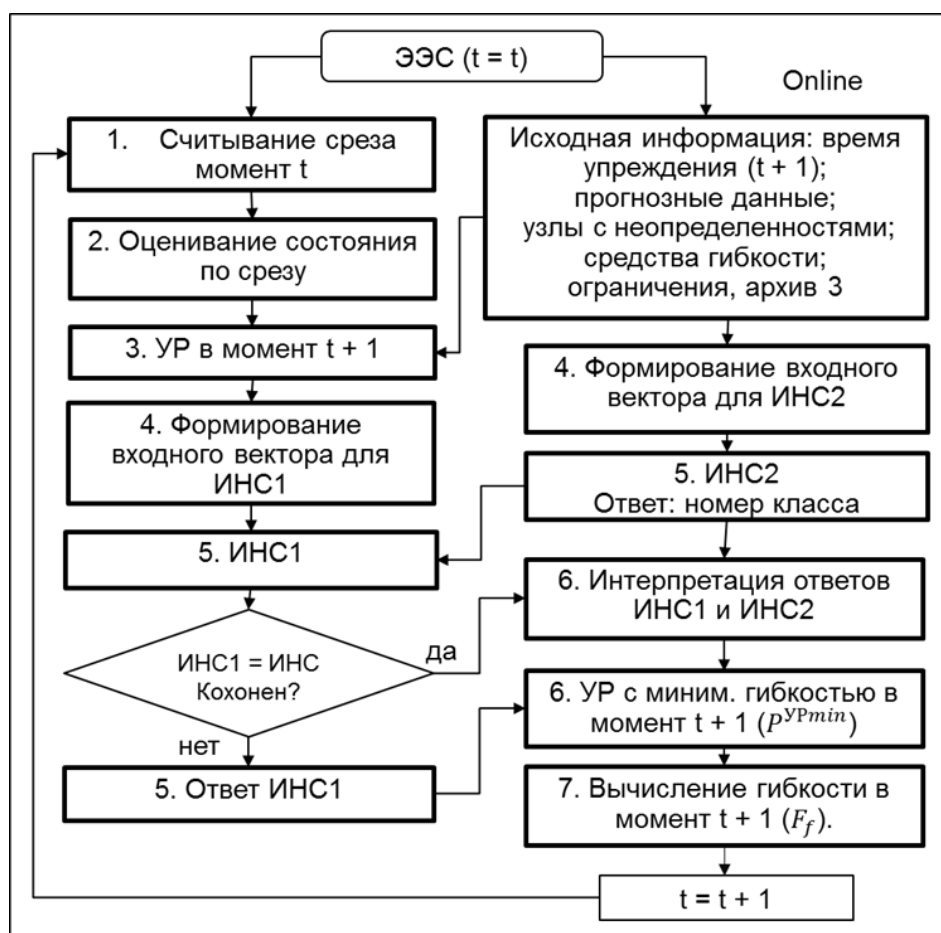


Рис. 2. Алгоритм вычисления гибкости электроэнергетической системы. Онлайн
 Fig. 2. Algorithm for calculating electric power system flexibility. Online

1. Собирается информация о состоянии ЭЭС с помощью систем сбора данных.

2. Решается задача оценивания состояния.

3. Вычисляются параметры режима на заданный $(t + 1)$ момент времени (исследуемый режим) по прогнозной информации (генерация на ветровой станции, мощность батареи, нагрузки). В качестве исходных приближений напряжения используются оценки параметров режима в момент времени t .

4. Формируются входные векторы для ИНС1 и ИНС2. Здесь под ИНС1 понимается многослойный персептрон или ИНС Кохонена, ИНС2 – это ИНС Кохонена.

5. Распознаются заданные условия (ограничения) с помощью ИНС2. ИНС2 выявляет свойства, которыми характеризуется исследуемый вектор ограничений, и распознает его как вектор, принадлежащий к одному из существующих классов. Порог схожести векторов определяется количеством классов.

6. Выполняется интерпретация ответов ИНС, то есть предлагается УР с минимальной гибкостью, соответствующий условиям, заданным входными данными. Многослойный персептрон по текущим параметрам режима и с учетом ответов ИНС2 прогнозирует параметры P_i^{ypmin} .

7. Вычисляется гибкость ЭЭС в исследуемом режиме. При этом вместе с абсолютными значениями ожидаемых нагрузок очень важным является их сочетание.

ФОРМИРОВАНИЕ ОКРУЖЕНИЯ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ (ОФЛАЙН)

Алгоритм формирования окружения.

Окружение или среда, в которой будет функционировать ИНС, формируется в следующем порядке.

1. Постановка задачи. Целью обучения ИНС является определение параметров УР с минимальной гибкостью.

2. Выбор типа ИНС. Тип ИНС выбирается в зависимости от конкретной постановки задачи. В данной работе рассматриваются две постановки задачи: прогнозирование и классификация. В связи с тем, что задачи

прогнозирования хорошо решаются многослойным персептроном, а для задач классификации часто применяются ИНС Кохонена, в работе выбираются два типа ИНС: многослойный персептрон и ИНС Кохонена.

3. Формирование обучающего задачника. Для обучения ИНС1 с парадигмой обучения с учителем формируется обучающий задачник, который состоит из входных и выходных примеров. Каждый входной пример формируется из данных архива 1 (см. рис. 1) и состоит из инъекций активной мощности в одном из исследуемых режимов P_i .

$$S1_{\text{вход}} = (P_1, P_2, \dots, P_i, \dots, P_n), \quad (5)$$

где n – количество узлов в ЭЭС.

Каждый выходной пример формируется из данных архива 3 (см. рис. 1) и состоит из инъекций активной мощности в УР с минимальной гибкостью P_i^{ypmin} .

$$S1_{\text{выход}} = (P_1^{ypmin}, P_2^{ypmin}, \dots, P_i^{ypmin}, \dots, P_n^{ypmin}). \quad (6)$$

Для обучения ИНС1 с парадигмой обучения без учителя обучающий задачник формируется из входных примеров, где каждый пример выглядит как (5).

Для обучения ИНС2 с парадигмой обучения без учителя требуются только входные данные. Каждый пример создается из ограничений, существующих в момент наступления исследуемого режима (см. рис. 1, архив 2):

$$S2_{\text{вход}} = (P_i^{\min}, P_i^{\max}, U_i^{\min}, U_i^{\max}, Q_i^{\min}, Q_i^{\max}). \quad (7)$$

В качестве ограничений используются следующие неравенства:

$$U_i^{\min} < U_i < U_i^{\max}; \quad (8)$$

$$Q_j^{\min} < Q_j < Q_j^{\max}; \quad (9)$$

$$P_j^{\min} < P_j < P_j^{\max}. \quad (10)$$

Набор примеров представляет собой обучающий задачник. Количество примеров в обучающем задачнике равно S .

4. Инициализация ИНС. На этапе инициализации определяются точности обучения и тестирования, количество циклов обучения, количество слоев, количество нейронов в каждом слое и другие стартовые параметры.

5. Обучение ИНС. ИНС обучается в течение заданного количества эпох. Затем полученные результаты оцениваются специалистом. Многослойный персептрон учится прогнозировать параметры УР с минимальной гибкостью. ИНС Кохонена выявляет отличительные и похожие свойства, которыми характеризуются исследуемые векторы (режимы для ИНС1 и ограничения для ИНС2) и классифицирует разные векторы в отдельные классы.

6. Тестирование ИНС. С целью определения способности обученной ИНС к обобщению выполняется тестирование ИНС на тестовой выборке. При допустимых ошибках тестирования обученная ИНС может быть применена для распознавания УР с минимальной гибкостью в режиме реального времени.

7. Интерпретация ответов. При решении задач прогнозирования интерпретация ответов не требуется. Ответом ИНС Кохонена является номер класса, к которому принадлежит входной вектор. В случае требования более детальной информации выполняется интерпретация ответов. В данном случае ответы ИНС1 (ИНС Кохонена) преобразуются в параметры УР с минимальной гибкостью (p_i^{UPmin}).

Точность результатов ИНС зависит от их структуры. В работе выполнено исследование по выбору оптимальной структуры ИНС1 по критерию максимальной корректности распознавания УР с минимальной гибкостью.

Определение оптимальной структуры искусственной нейронной сети многослойного персептрона

Для выбора структуры многослойного персептрона (далее ИНС_п) выполняется множество расчетов по алгоритму, показанному на рис. 3. Алгоритм состоит из двух блоков.

В начале алгоритма задается количество рассматриваемых структур ИНС, которое определяет число расчетов.

В блоке 1:

1. Задается структура ИНС_п. В данном случае под заданием структуры понимается установление числа нейронов в скрытом слое.

2. Обучается ИНС. ИНС обучается за T (период) эпох методом обратного распространения ошибки (алгоритм Левенберга–Марквардта) [19].

3. Тестируется ИНС.

4. Вычисляются ошибки тестирования и ошибки проверки.

Ошибки тестирования определяются по формулам:

1. Средняя ошибка тестирования Δ_{M1} :

$$\Delta_{M1} = \sum_{j=1}^{v_2} (\sum_{i=1}^v |\delta P_{ij}| / v) / v_2, \quad (11)$$

где δP_{ij} – ошибка обучения, вычисленная для одного параметра в примере; v_2 – количество примеров в тестовой выборке; v – количество параметров в примере; i – номер параметра в примере; j – номер примера в тестовой выборке.

2. Средняя максимальная ошибка тестирования Δ_{M2} :

$$\Delta_{M2} = \sum_{j=1}^{v_2} \max |\delta P_{ij}| / v_2. \quad (12)$$

Ошибки проверки, которые вычисляются в процессе обучения ИНС (validation error), определяются по следующим формулам:

3. Средняя ошибка Δ_{M3} :

$$\Delta_{M3} = \sum_{j=1}^{v_3} (\sum_{i=1}^v |\delta P_{ij}| / v) / v_3. \quad (13)$$

4. Средняя максимальная ошибка Δ_{M4} :

$$\Delta_{M4} \sum_{j=1}^{v_3} \max |\delta P_{ij}| / v_3, \quad (14)$$

где v_3 – количество примеров в проверочной выборке (validation dataset).

В блоке 2 вычисляется критерий и сохраняется информация о структуре ИНС, которая оказывается оптимальной среди рас-

смотренных на данный момент структур.

Критерий оптимальности записывается следующим образом:

$$\rho_{\Pi(g)} \rightarrow \min; \quad (15)$$

$$\rho_{\Pi(g)} = \Delta_{M1} + \Delta_{M2} + \Delta_{M3} + \Delta_{M4}, \quad (16)$$

где g – номер расчета.

По окончании работы блока 2 обученная ИНС_п имеет оптимальную структуру.

Определение оптимальной структуры искусственной нейронной сети Кохонена. На этапе подготовки ИНС Кохонена [20] выбираются структуры двух нейронных сетей: основной (далее ИНС_К1) и вспомогательной (далее ИНС_К2). Ответы вспомогательной ИНС применяются при интерпретации результатов основной ИНС. Для выбора структуры, которая обеспечит правильную интерпретацию ответов ИНС_К1 с помощью ИНС_К2 (далее оптимальная структура), выполняется множество расчетов по алгоритму, представленному на рис. 4.

В начале алгоритма задаются константы

и исходные значения некоторых переменных ρ_K^{\min} . Каждому расчету соответствует определенная структура основной (ИНС_К1) и вспомогательной (ИНС_К2) нейронных сетей Кохонена.

В блоке 1 задаются структуры основной ИНС_К1 и вспомогательной ИНС_К2 нейронных сетей. Под заданием структуры понимается назначение количества классов, на которые классифицируются входные (используется ИНС_К1) и выходные (используется ИНС_К2) примеры. Количество классов основной и вспомогательной ИНС совпадают. После обучения и тестирования нейронных сетей (ИНС_К1 и ИНС_К2) на обучающем и тестовом задачниках вычисляются ошибки обучения Δ_{K1} и тестирования Δ_{K2} :

$$\Delta_k = 1/m_b (\sum \Delta_{i_абс}), \quad (17)$$

где Δ_k – ошибка обучения или тестирования; m_b – количество примеров обучающей или тестовой выборки; $\Delta_{i_абс} = 0$, если ответ ИНС корректный; $\Delta_{i_абс} = 1$, если ответ ИНС ошибочный.

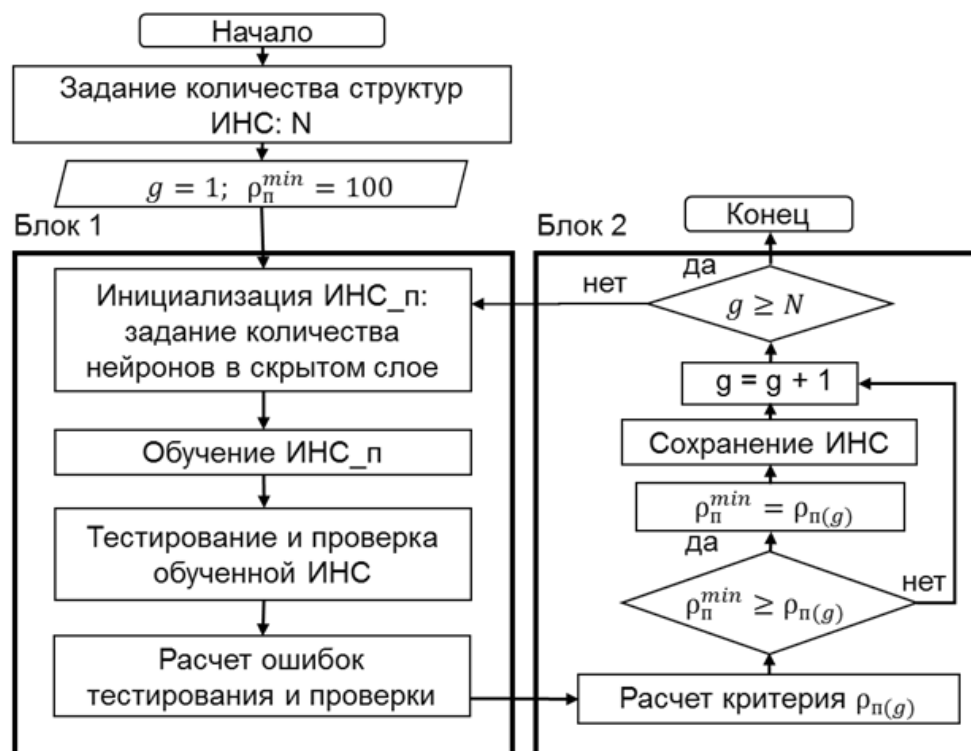


Рис. 3. Алгоритм подбора структуры многослойного персептрона
Fig. 3. Algorithm for multilayer perceptron structure selection

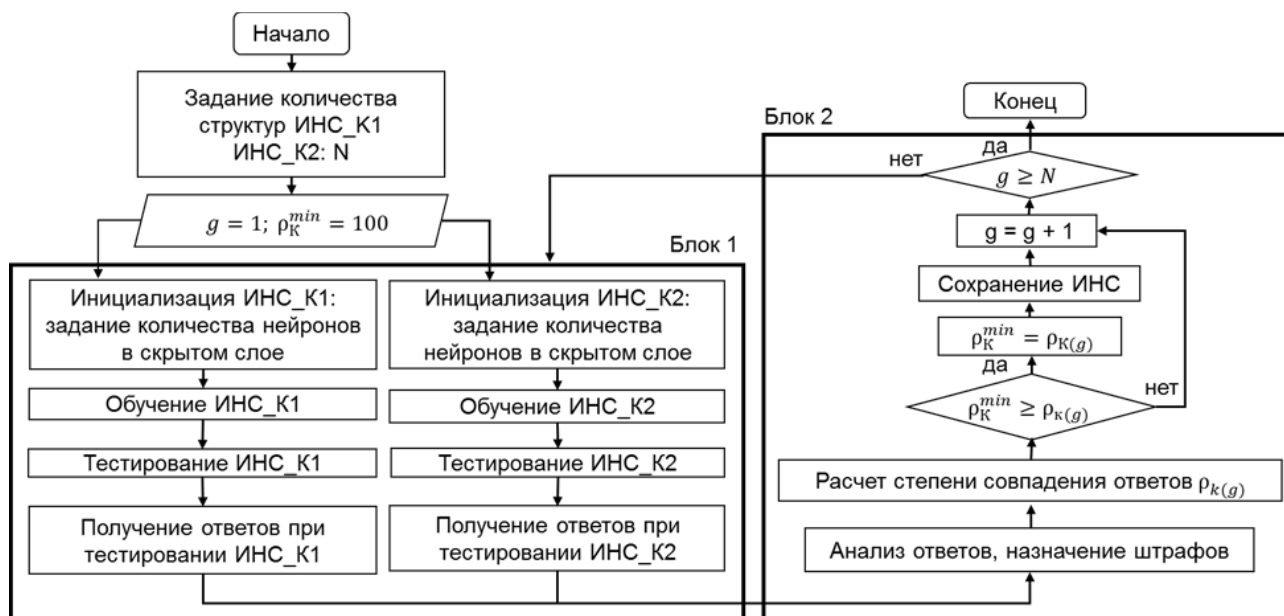


Рис. 4. Алгоритм подбора структуры сети Кохонена
 Fig. 4. Kohonen network structure selection algorithm

В блоке 2 выполняется анализ критерия на предмет выбора оптимальной структуры обеих ИНС. Структура ИНС рассматривается оптимальной в случае максимального совпадения ответов двух ИНС (ИНС_K1 и ИНС_K2). Это означает, что примеры входной выборки классифицируются нейронной сетью ИНС_K1, точно так же как примеры выходной выборки классифицируются нейронной сетью ИНС_K2.

Критерий выбора оптимальной структуры двух ИНС записывается следующим образом:

$$\rho_{K(g)} \rightarrow \min; \quad (18)$$

$$\rho_{K(g)} = \varepsilon_{k1} + \varepsilon_{k2} + \varepsilon_{k3}, \quad (19)$$

при ограничениях

$$\Delta_{K1} < \Delta_{\varepsilon1}, \quad (20)$$

$$\Delta_{K2} < \Delta_{\varepsilon2}, \quad (21)$$

где g – номер расчета; $\Delta_{\varepsilon1}$, $\Delta_{\varepsilon2}$ – точность тестирования ИНС_K1 и ИНС_K2, соответственно; ε_{k1} – штраф за наличие пустых классов при классификации примеров; ε_{k1} равно числу пустых классов; ε_{k2} – штраф за

лишние или отсутствующие примеры в классе. ε_{k2} рассчитывается по формуле:

$$\varepsilon_{k2} = \left(\sum_{k=1}^m \left(\frac{n_{in} - n_{out}}{n_{in}} \right) \right) / m, \quad (22)$$

где n_{in} – количество входных примеров в классе; n_{out} – количество выходных примеров в классе; m – количество классов.

ε_{k3} – дисперсия ряда, которая отвечает за совпадение ответов ИНС_K1 и ИНС_K2, вычисленная по формуле:

$$\varepsilon_{k3} = \frac{1}{(v_1 + v_2)} (\sum_1^{v_1 + v_2} \sigma_{i(j)}^2); \quad (23)$$

$$\sigma_{i(j)}^2 = \sum_1^k w_l^2 - w_{cp}^2 / k - 1, \quad (24)$$

где i – номер класса при обучении ИНС_K1; j – номер класса при обучении ИНС_K2; w_l – класс, в который попал пример; w_{cp} – среднее значение номеров классов, в которые попали примеры. Дисперсии ответов количественно показывают совпадение ответов ИНС_K1 и ИНС_K2. Если дисперсия равна нулю и количество примеров совпало, то рассматриваемый класс имеет нулевую погрешность.

На каждом цикле расчета ρ_K^{min} сравнивается с предыдущим значением и если новое

значение меньше, то ИНС_K сохраняется до следующего меньшего значения ρ_K . Наименьшее значение ρ_k^{min} обеспечивает максимальное совпадение ответов ИНС_K1 и ИНС_K2, что обуславливает возможность использования выбранной структуры ИНС_K1 в реальном времени.

Результатом работы алгоритма являются обученные ИНС_K1 и ИНС_K2, структуры которых являются оптимальными среди рассмотренных структур.

ПРАКТИЧЕСКИЕ ИССЛЕДОВАНИЯ

Описание тестовой схемы и сценария. Апробация предложенного алгоритма была выполнена на 6-узловой ЭЭС (рис. 5) по сценарию: вычислить гибкость ЭЭС, функционирующих в разных режимах при одинаковых ограничениях.

В табл. 1 представлены характерные особенности каждого узла. В строке 1 расположены номера узлов, в строке 2 дано описание типа узла, в строке 3 представлена ха-

рактеристика каждого генерирующего узла, в строке 4 отмечены узлы, обеспечивающие гибкость ЭЭС, в строке 5 отмечены узлы с неопределенностью.

Формирование архивов. В предлагаемом сценарии рассматривается один набор ограничений и допускается, что результаты оценивания состояния – это параметры исследуемого УР, т.к. измерения моделируются на момент времени $t + 1$. Модель измерения записывается следующим образом:

$$\bar{y} = y_{ист} + x_{сл}\sigma_y, \quad (25)$$

где $x_{сл} \in N(0,1)$; σ_y^2 – дисперсия измерения; $y_{ист}$ – истинное значение; $x_{сл}$ – это случайная величина, полученная с помощью датчика случайных чисел.

Для моделирования архива срезов измерений требуется следующая информация:

1. Суточные графики активной и реактивной нагрузок в узлах 3, 4 (24 точки).




Рис. 5. Тестовая схема
Fig. 5. Test circuit

Таблица 1. Характеристики узлов
Table 1. Node characteristics

Информация об узле	Номер узла					
	1	2	3	4	5	6
1	ветровая	традиционная	нагрузка	нагрузка	батарея	традиционная
2		управляющие воздействия				балансирующая
3					+	+
4		+	+	+		+

2. Суточные графики активной и реактивной генераций в узле 1 (ветровая станция). Генерация активной мощности на ветровой станции вычисляется на основе информации о скорости ветра и типовой кривой ветровой турбины. Скорость ветра моделируется по распределению Вейбула.

3. Суточный график зарядки батареи SOC (от англ. State of Charge) в узле 5. Мощность батареи вычисляется в соответствии со стратегией управления аккумуляторной батареей: максимизировать использование возобновляемой энергии ветра с помощью батареи.

4. Значения активной и реактивной мощности в узле 2.

Архивы УР и УР с минимальной гибкостью формируются в следующем порядке:

1. Вычисляется установившийся режим для каждой точки графиков генерации и нагрузки. Балансирующим узлом назначается узел 6. Результаты расчета УР рассматриваются как эталонные параметры. В модели измерения они принимаются за истинные значения $y_{ист}$.

2. Моделируется срез измерений. К истинным значениям измеряемых параметров режима $y_{ист}$ добавляются погрешности измерения $x_{сл}\sigma_y$. Для одной и той же точки УР моделируется 6 срезов. Это означает, что параметры режима измеряются каждые 10 мин.

3. Выполняется ОС по смоделированному срезу измерений. Полученный УР записывается в архив 1.

4. Вычисляется УР с минимальной гибкостью и записывается в архив 3. Для расчета УР с минимальной гибкостью могут быть применены разные методы.

Данные архива 1 (активные мощности во всех узлах в исследуемом режиме) используются для создания входных примеров, а данные архива 3 (активные мощности во всех узлах в УР с минимальной гибкостью) используются для создания выходных примеров задачника. Сформированный задачник разбивается на обучающую, проверочную и тестовую выборки. Обучающая выборка включает 70% примеров из всего задачника (94 примера), проверочная выборка состоит из 15% (20 примеров), тестовая выборка включает 15% (20 примеров).

По сформированным задачникам обучается и тестируется ИНС с парадигмой «обучение с учителем» (ИНС_п). Для обучения и тестирования ИНС с парадигмой «обучение без учителя» (ИНС_{K1}) требуются только входные данные обучающей и тестовой выборок. По выходным данным обучающего и тестового задачников обучается и тестируется ИНС_{K2}, результаты которой необходимы для интерпретации ответов ИНС_{K1}.

На рис. 6 и 7 представлены по 10 примеров входных и выходных данных сформированного задачника. Один столбец в каждой табл. соответствует одному примеру.

Входной пример задачника состоит из: $S1_{вход} = (P_1, P_2, P_3, P_4, P_5, P_6)$.

Выходной пример задачника состоит из: $S1_{выход} = (P_1, P_2^{ypmin}, P_3^{ypmin}, P_4^{ypmin}, P_5, P_6^{ypmin})$.

Далее подробно описывается формирование (моделирование, обучение и тестирование) двух ИНС для использования их в режиме реального времени. Программная реализация нейронных сетей была выполнена в среде MatLab.

sxem6_in										
	1	2	3	4	5	6	7	8	9	10
1	P_1	28.5510	27.6610	28.1310	28.7860	27.4360	28.3470	28.4220	27.7980	28.7370
2	P_2	17.7560	19.4520	18.9910	18.3960	19.0120	18.9110	19.1720	19.8340	19.4570
3	P_3	-10.3840	-11.3640	-9.3843	-10.1320	-10.1300	-10.8560	-9.5544	-9.8457	-9.8745
4	P_4	-17.7310	-18.9120	-19.2810	-18.3910	-18.4320	-17.6230	-19.1200	-18.7920	-18.2260
5	P_5	-6.5077	-7.1738	-6.4041	-6.2323	-7.6922	1.5493	-0.9912	-0.4689	-1.6792
6	P_6	13.4830	13.0700	13.5800	13.0570	12.5090	12.7500	12.6110	12.7870	12.6780

Рис. 6. Фрагмент задачника с входными данными
 Fig. 6. A fragment of the task book with input data

sxemb_out_ch										
	1	2	3	4	5	6	7	8	9	10
1	P_1	28.5290	27.8560	28.0500	28.7650	27.4660	27.8470	27.9600	27.5710	28.3860
2	P_2	32.6790	32.9840	32.7600	32.3100	32.9750	32	32.2520	32.7790	32.1930
3	P_3	-20.1950	-22.1420	-19.7390	-20.0710	-20.0520	-19.1030	-19.9930	-21.6810	-21.7690
4	P_4	-22.8710	-21.0220	-22.9660	-22.4020	-22.3980	-23.8730	-23.0780	-20.4940	-20.1600
5	P_5	-6.5255	-6.9811	-6.4847	-6.2510	-7.6763	1.0472	-1.4499	-0.6950	-2.0277
6	P_6	12.9790	12.8790	13.1210	12.4390	12.5830	11.7690	11.4600	12.1230	11.6650

Рис. 7. Фрагмент задачника с выходными данными
Fig. 7. A fragment of the task book with output data

Формирование окружения для многослойного персептрона. Для выбора структуры ИНС_п, обеспечивающей лучшие результаты прогнозирования УР с минимальной гибкостью, было проведено 20 экспериментов по алгоритму, представленному на рис. 3. В первом эксперименте количество нейронов в скрытом слое равно 6 и далее увеличивается до 166. В ходе вычислительного эксперимента отслеживалась динамика изменения критерия ρ_{Π} в зависимости от числа нейронов в скрытом слое ИНС_п (рис. 8). На рис. 8 сплошной линией показаны значения ρ_{Π} для каждого расчета, прямой линией обозначен предел, ниже которого располагаются значения критериев трех лучших структур.

В табл. 2 записаны значения критерия ρ_{Π} и количество нейронов в скрытом слое для выбранных структур ИНС.

В процессе эксперимента были выявлены близкие значения критерия ρ_{Π} для трех структур ИНС_п. Для уточнения полученных данных с целью окончательного выбора

структуры ИНС_п были проведены дополнительные расчеты. Под уточнением полученных данных понимается определение среднестатистического значения критерия ρ_{Π} в результате многократного обучения ИНС_п с тремя выбранными структурами. Каждая из ИНС обучалась 30 раз, после чего были вычислены среднестатистические значения средних и максимальных ошибок тестирования и проверки для каждой из трех ИНС. Результаты расчетов представлены в табл. 3. Из табл. 3 видно, что ИНС с 16 нейронами в скрытом слое имеет лучшие показатели.

Таблица 2. Значения критериев для выбранных искусственных нейронных сетей

Table 2. Criteria values for selected artificial neural networks

Место в рейтинге	Количество нейронов	ρ_{Π}
1	16	2,7014
2	6	3,9081
3	146	4,264




Рис. 8. Значение ρ_{Π} для каждого расчета
Fig. 8. Value of ρ_{Π} for each calculation

Таблица 3. Среднестатистические величины ошибок тестирования и проверки
 Table 3. Average statistical values of testing and verification errors

Число нейронов	Средняя ошибка		Максимальная ошибка	
	тестирования	проверки	тестирования	проверки
6	0,233	0,245	1,785	1,782
16	0,216	0,271	1,676	1,766
146	0,349	0,382	2,558	2,871

Формирование окружения для искусственных нейронных сетей Кохонена.

Для выбора структуры ИНС_K1 и ИНС_K2, обеспечивающих лучшие результаты распознавания УР с минимальной гибкостью при соблюдении ограничений (20), (21), было проведено 10 экспериментов по алгоритму, представленному на рис. 4. В первом эксперименте обучались ИНС Кохонена минимального размера (3 нейрона в выходном слое), в последующих экспериментах размер ИНС постепенно увеличивался (до 12 нейронов). После каждого увеличения количества нейронов ИНС обучались заново.

По результатам экспериментов была составлена табл. 4, в которой представлены значения критерия ρ_K и величины штрафов ε_{K1} , ε_{K2} , ε_{K3} , назначенные за несовпадение ответов ИНС_K1 и ИНС_K2. В первой строке табл. 4 записан номер эксперимента, во второй строке показано число нейронов в выходном слое каждой ИНС (ИНС_K1 и ИНС_K2). В третью, четвертую, пятую строки записываются величины штрафов, назначенные за наличие пустых классов (пустые классы образуются при использовании ИНС с ко-

личеством выходных нейронов равными 11 и 12); за лишние или отсутствующие примеры в классе, за некорректную классификацию примеров. ε_{K2} , ε_{K3} вычисляется по (22) и (23), соответственно.

Из табл. 4 видно, что минимальное значение ρ_K получено при использовании ИНС с тремя нейронами в выходном слое. В табл. 5 представлены ошибки тестирования ИНС_K1 и ИНС_K2.

По представленным в табл. 5 результатам построена зависимость абсолютного значения средней ошибки тестирования от числа нейронов в выходном слое (рис. 9). Пунктирной линией показана заданная точность тестирования ($\Delta_K = 0,1$). Анализ рис. 9 показывает, что:

- наблюдается уменьшение величины ошибки с ростом количества нейронов до 9, далее средняя ошибка увеличивается;
- величина ошибки тестирования ИНС с тремя нейронами ($\Delta_{K1} = 0,104$) превышает заданную точность;
- величина ошибки тестирования ИНС с другими рассмотренными конфигурациями удовлетворяют ограничениям (20), (21).

Таблица 4. Результаты расчетов
 Table 4. Calculation results

1	№	1	2	3	4	5	6	7	8	9	10
2	Количество	3	4	5	6	7	8	9	10	11	12
3	ε_{K1}	0	0	0	0	0	0	0	0	1	2
4	ε_{K2}	9,64	15,26	18,24	26,89	17,36	47,29	14,07	15,39	150,67	2,95
5	ε_{K3}	0,016	0,045	0,126	0,258	0,505	0,359	0,108	0,481	0,386	0,285
6	ρ_K	9,66	15,314	18,371	27,157	17,874	47,649	14,182	15,875	17,056	23,243

Таблица 5. Ошибки тестирования искусственной нейронной сети _K1 и искусственной нейронной сети _K2
 Table 5. Testing errors of artificial neural networks _K1 and _K2

Количество	3	4	5	6	7	8	9	10	11	12
Δ_{K1}	0,104	0,089	0,074	0,067	0,05	0,052	0,044	0,052	0,044	0,052
Δ_{K2}	0,097	0,082	0,082	0,044	0,059	0,052	0,029	0,022	0,037	0,044




Рис. 9. Влияние числа нейронов на ошибку обучения нейронной сети
Fig. 9. Number of neurons vs value of the neural network training error

Анализ табл. 4 и рис. 9 показывает, что оптимальной структурой каждой ИНС является ИНС с 9-ю нейронами в выходном слое (расчет № 7), т.к. в этом случае выполняются ограничения, и значение ρ_K оказывается наименьшим среди оставшихся (табл. 4, строка 6). Это означает, что при использовании данной структуры обеспечивается лучшее совпадение результатов ИНС_K1 и ИНС_K2.

Для визуализации меры совпадения ответов ИНС_K1 и ИНС_K2 построены диаграммы попадания примеров в классы (рис. 10). На верхней диаграмме показано распределение входных примеров, выполненное с помощью ИНС_K1, на нижней диаграмме представлено распределение, выполненное с помощью ИНС_K2. Каждый шестиугольник является нейроном (центром класса), где цифра отражает число примеров, связанных с этим нейроном. Размер темного пятна в шестиугольнике показывает долю примеров от максимального числа примеров, принадлежащих к одному из классов (класс с максимальным количеством примеров закрашивается полностью). Стрелки указывают на соответствие ответов ИНС_K1 и ИНС_K2. Например, 23 примера были распределены с помощью ИНС_K1 в класс 4, а с помощью ИНС_K2 – в класс 8. Дисперсия ряда, который отвечает за совпадение ответов ИНС_K1 и ИНС_K2, в данном случае равна 0 (полное

совпадение). Средняя величина дисперсии рядов, отвечающих за совпадение ответов ИНС_K1 и ИНС_K2 равна 0,108, что рассматривается допустимым.

Представленные диаграммы и малые величины штрафов за некорректность ответов подтверждают возможность использования ИНС с девятью нейронами в выходном слое для расчета гибкости ЭЭС в режиме реального времени.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ

Вычисление гибкости исследуемого режима с помощью разработанного алгоритма, показанного на рис. 2, в условиях реального времени выполняется в следующем порядке:

- 1) из текущего среза измерений формируется входной пример для ИНС_K1;
- 2) обученная ИНС_K1 распознает текущий режим и распределяет его к одному из классов;
- 3) по номеру класса определяется соответствующий данному классу режим с минимальной гибкостью;
- 4) вычисляются качественный и количественный показатели гибкости.

Далее показаны результаты вычисления гибкости пяти режимов тестовой схемы.

На рис. 11 представлены входные векторы, сформированные из пяти исследуемых режимов. На рис. 12 показаны ответы ИНС_K1, интерпретированные с помощью

ИНС_K2 (далее – выходные примеры). Выходные примеры представляют собой параметры УР с минимальной гибкостью, соответствующие текущим (исследуемым) режимам.

Для визуализации процесса вычисления гибкости результаты представлены в графическом виде (рис. 13). Входной пример каждого исследуемого режима состоит из шести параметров, поэтому входное пространство – шестимерное. На рис. 13 показаны три координаты шестимерного пространства: ось

абсцисс – P_1 (активная мощность в узле 1); ось ординат – P_2 (активная мощность в узле 2); ось аппликата – P_3 (активная мощность в узле 3).

На рис. 13 а точками представлены входные примеры в трехмерном пространстве, где цифра обозначает номер примера. На рис. 13 б показаны расположения входных и выходных примеров. Параметры режимов с минимальной гибкостью отображены треугольниками.




Рис. 10. Диаграммы попадания примеров в классы
Fig. 10. Diagrams of examples falling into classes

26.8998	20.2902	19.0176	23.0391	22.4553
18.9413	19.8224	18.5063	18.1164	18.5351
-10.1372	-10.0342	-14.7691	-17.3225	-16.6553
-18.5030	-16.8861	-18.7047	-17.9742	-18.2583
-7.3012	0.4049	0.4751	-5.6397	-8.0523
13.0180	11.0414	10.7697	13.0358	12.1588

Рис. 11. Входные векторы
Fig. 11. Input vectors

27.2074	21.4866	17.5542	27.5832	22.9381
34.0616	32.2865	32.1320	29.3024	21.2913
-19.1738	-22.0641	-19.4705	-22.7842	-21.4099
-22.6988	-18.6875	-23.8926	-20.0612	-18.5291
-6.6138	-0.9249	0.5867	-8.0257	-7.0973
11.6947	12.7817	11.9392	13.1392	12.7757

Рис. 12. Выходные векторы
Fig. 12. Output vectors

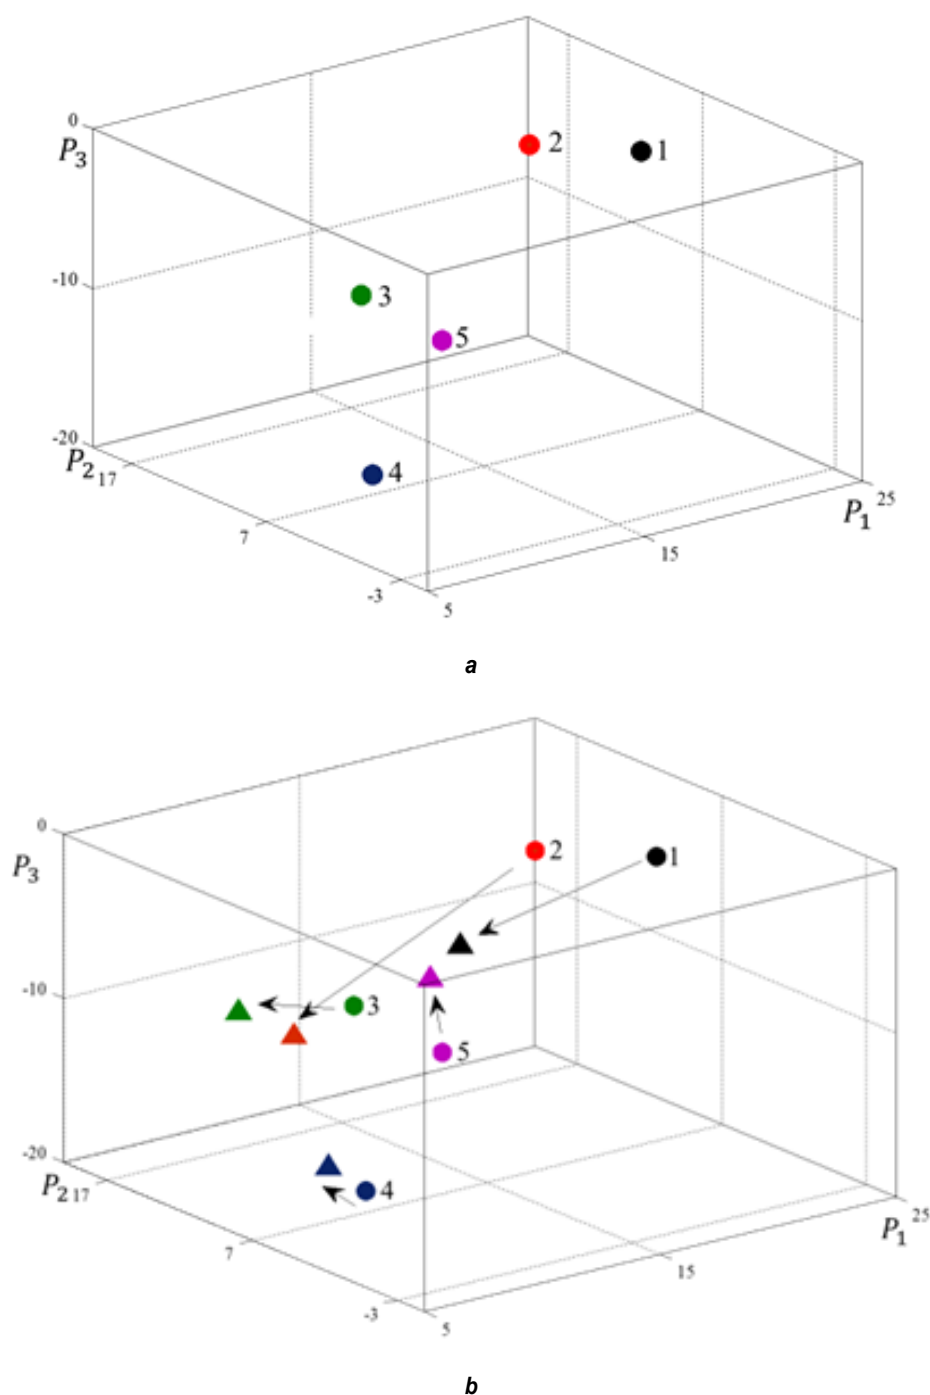



Рис. 13. Координаты входных и выходных примеров в трехмерном пространстве:
***a* – расположение входных примеров; *b* – расположение входных и выходных примеров**
Fig. 13. Coordinates of input and output examples in a three-dimensional space:
***a* – location of input examples; *b* – location of input and output examples**

На рис. 14 показаны активные мощности в узлах 3 (рис. 14 а) и 4 (рис. 14 б) в текущих режимах (белые столбцы) и в режимах с минимальной гибкостью (серые столбцы). Разница между величинами столбцов показывает запас гибкости.


Из рис. 14 видно, что:

– во всех рассмотренных режимах ЭЭС обладает гибкостью;

– гибкость пяти исследуемых режимов равна 13,23 МВт в первом режиме, 13,83 МВт – во втором, 9,88 МВт – в третьем, 7,54 МВт – в четвертом и 5,02 МВт – в пятом режимах, соответственно.



a



b

Рис. 14. Активные мощности в текущем установившемся режиме и установившемся режиме с минимальной гибкостью: а – 3 узел; б – 4 узел
 Fig. 14. Active power in the current steady-state mode and the steady-state mode with minimal flexibility: а – 3 node; б – 4 node

ЗАКЛЮЧЕНИЕ

В работе описана проблема, связанная с применением искусственных нейронных сетей при решении задачи определения гибкости ЭЭС в режиме реального времени. Про-

веденный обзор статей, выполненный по данной тематике, позволяет сказать, что проблема определения гибкости ЭЭС является новой важной задачей среди задач, обеспечивающих надежное и эффективное

управление ЭЭС. Для определения гибкости ЭЭС с возобновляемыми источниками энергии, которые обладают стохастическими характеристиками, необходимы методы, позволяющие учитывать реальные условия работы данных систем. Выполнение этого требования возможно за счет применения ИНС.

Разработан алгоритм для анализа результатов двух типов ИНС с разными структурами (многослойный персептрон и ИНС Кохонена). Смоделировано множество структур ИНС каждого типа с целью формирования ИНС, обеспечивающих максимальную способность к обобщению. Разработан алгоритм выбора оптимальных структур ИНС в соответствии с критерием максимальной достоверности ответов при распознавании УР с минимальной гибкостью. ИНС с оптимальной структурой рекомендуется к применению в режиме реального времени при определении гибкости ЭЭС.

Предложен оригинальный способ интерпретации ответов ИНС Кохонена, для которого требуются ответы другой ИНС Кохонена. Для корректной интерпретации ответов ИНС_K1 проводится предварительное исследование по выбору структур двух ИНС (ИНС_K1, ИНС_K2). Показано, что при определенных структурах ИНС_K1, ИНС_K2 отве-

ты ИНС_K1 интерпретируются правильно.

В результате множества экспериментов сформированы окружения искусственных нейронных сетей для прогнозирования и распознавания УР с минимальной гибкостью 6-узловой схемы. Анализ среднестатистических средних и максимальных ошибок тестирования и проверки многослойного персептрона показывает, что ИНС с 16-ю нейронами в скрытом слое является оптимальной для определения УР с минимальной гибкостью в режиме реального времени. Анализ критерия оптимальности при выборе ИНС Кохонена показывает, что структура ИНС с девятью выходными нейронами является оптимальной для определения УР с минимальной гибкостью в режиме реального времени.

Выполнены расчеты гибкости пяти режимов тестовой схемы. Анализ результатов показал, что величина гибкости разная в различных режимах, что подтверждает необходимость определения гибкости ЭЭС в режиме реального времени.

Применение разработанных алгоритмов позволит осуществлять мониторинг гибкости ЭЭС в режиме реального времени с целью повышения качества оперативного управления режимами ЭЭС и более полного использования ресурсов ЭЭС.

Список источников

1. Mohandes B., Moursi M. S. E., Hatziaargyriou N., Khatib S. E. A review of power system flexibility with high penetration of renewables // IEEE Transactions on Power Systems. 2019. Vol. 34. Iss. 4. P. 3140–3155. <https://doi.org/10.1109/TPWRS.2019.2897727>.
2. Rebours Y., Kirschen D. S., Trotignon M., Rossignol S. A survey of frequency and voltage control ancillary services – Part I: Technical features // IEEE Transactions on Power Systems. 2007. Vol. 22. Iss. 1. P. 350–357. <https://doi.org/10.1109/TPWRS.2006.888963>.
3. Terras J. M., Catia S., Zita V., Faria P. Consumers modelling and clustering for the use of flexibility to mitigate network congestion // Proceedings Journal. 2020. Vol. 2020. Iss. 1. P. 364–367. <https://doi.org/10.1049/oap-cired.2021.0059>.
4. Сидорович В., Бокарев Б., Чаусов И., Кулешов М., Рычков С., Бурдин И. Управление спросом в электроэнергетике России: открывающиеся возможности. Экспертно-аналитический доклад // Инфраструктурный центр EnergyNet. Москва, 2019. [Электронный ресурс]. URL: https://www.so-ups.ru/fileadmin/files/company/markets/dr/publication/EnergyNet_2019.pdf (12.03.2021).
5. Bell K. R. W., Nedic D. P., Martin L. A. S. S. The need for interconnection reserve in a system with wind generation // IEEE Transactions on Sustainable Energy. 2012. Vol. 3. Iss. 4. P. 703–712. <https://doi.org/10.1109/TSTE.2012.2208989>.
6. Chicco G., Riaz S., Mazza A., Mancarella P. Flexibility from distributed multienergy systems // Proceedings of the IEEE. 2020. Vol. 108. Iss. 9. P. 1496–1517. <https://doi.org/10.1109/JPROC.2020.2986378>.
7. Klyapovskiy S., You Shi, Michiorri A., Kariniotakis G., Bindner H.W. Incorporating flexibility options into distribution grid reinforcement planning: a techno-economic framework approach // Applied Energy. 2019. Vol. 254. P. 113662. <https://doi.org/10.1016/j.apenergy.2019.113662>.
8. Krč R., Kratochvilova M., Podroužek J., Apeltauer T., Stupka V., Pitner T. Machine learning-based node characterization for smart grid demand response flexibility assessment // Sustainability. 2021. Vol. 13. Iss. 5. P. 2954. <https://doi.org/10.3390/su13052954>.
9. Förderer K., Ahrens M., Bao Kaibin, Mauser I., Schmeck H. Towards the modeling of flexibility using artificial neural networks in energy management and smart grids: note // e-Energy '18: Proceedings of the Ninth Inter-

national Conference on Future Energy Systems (Karlsruhe, 12–15 June 2018). Karlsruhe, 2018. P. 85–90. <https://doi.org/10.1145/3208903.3208915>.

10. Förderer K., Ahrens M., Bao Kaibin, Mauser I., Schmeck H. Modeling flexibility using artificial neural networks // *Proceedings of the 7th DACH + Conference on Energy Informatics*. 2018. Vol. 21. P. 73–91. <https://doi.org/10.1186/s42162-018-0024-4>.

11. Hammami Z., Mouchaweh M. S., Mouelhi W., Said L. B. Discussion and review of the use of neural networks to improve the flexibility of smart grids in presence of distributed renewable resources // *17th IEEE International Conference on Machine Learning and Applications* (Orlando, 17–20 December 2018). Orlando: IEEE, 2018. P. 1304–1309. <https://doi.org/10.1109/ICMLA.2018.00211>.

12. MacDougall P., Kosek A. M., Bindner H., Deconinck G. Applying machine learning techniques for forecasting flexibility of virtual power plants // *IEEE Electrical Power and Energy Conference*. 2016. <https://doi.org/10.1109/EPEC.2016.7771738>.

13. Maruf M. N. I., Munoz L. A. H., Nguyen P. H., Ferreira H. M. L., Kling W. L. An enhancement of agent-based power supply-demand matching by using ANN-based forecaster // *4th IEEE PES Innovative Smart Grid Technologies Europe*. 2013. <https://doi.org/10.1109/ISGTEurope.2013.6695257>.

14. Coccia G., Mugnini A., Polonara F., Arteconi A. Artificial-neural-network-based model predictive control to exploit energy flexibility in multi-energy systems comprising district cooling // *Energy*. 2021. Vol. 222. <https://doi.org/10.1016/j.energy.2021.119958>.

15. Baboli P. T., Babazadeh D., Bowatte D. R. K. Measurement-based modeling of smart grid dynamics: a digital twin approach // *10th Smart Grid Conference*. 2020. <https://doi.org/10.1109/SGC52076.2020.9335750>.

16. Глазунова А. М., Аксаева Е. С. Оценка гибкости электроэнергетической системы с ветровыми станциями и накопителями энергии в режиме реального времени // *Электроэнергия. Передача и распределение*. 2021. № 3. С. 24–31.

17. Glazunova A., Aksaeva E., Semshikov E., Negnevitsky M. Determining the flexibility of power systems with high share of wind generation using artificial neural networks // *31st Australasian Universities Power Engineering Conference*. 2021. <https://doi.org/10.1109/AUPEC52110.2021.9597838>.

18. Аксаева Е. С., Глазунова А. М. Использование искусственных нейронных сетей при определении гибкости электроэнергетической системы // *Методические вопросы исследования надежности больших систем энергетики. Надежность систем энергетики в условиях их цифровизации: 93-е заседание семинара (г. Волжский, 13–17 сентября 2021 г.)*. Волжский, 2021. С. 272–282.

19. Пархоменко С. С., Леденева Т. М. Обучение нейронных сетей методом Левенберга–Марквардта в условиях большого количества данных // *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*. 2014. № 2. С. 98–106.

20. Кохонен Т. Самоорганизующиеся карты / пер. 3-го англ. изд. М.: Бином. Лаборатория знаний, 2008. 655 с.

References

1. Mohandes B., Moursi M. S. E., Hatziaargyriou N., Khatib S. E. A review of power system flexibility with high penetration of renewables. *IEEE Transactions on Power Systems*. 2019;34(4):3140–3155. <https://doi.org/10.1109/TPWRS.2019.2897727>.

2. Rebours Y., Kirschen D. S., Trotignon M., Rossignol S. A survey of frequency and voltage control ancillary services – Part I: Technical features. *IEEE Transactions on Power Systems*. 2007;22(1):350–357. <https://doi.org/10.1109/TPWRS.2006.888963>.

3. Terras J. M., Catia S., Zita V., Faria P. Consumers modelling and clustering for the use of flexibility to mitigate network congestion. *Proceedings Journal*. 2020;2020(1):364–367. <https://doi.org/10.1049/oap-cired.2021.0059>.

4. Sidorovich V., Bokarev B., Chaousov I., Kuleshov M., Rychkov S., Burdin I. Demand management in the Russian energy sector: emerging opportunities. Expert-analytical report. *EnergyNet*. 2019. Available from: https://www.soups.ru/fileadmin/files/company/markets/dr/publication/EnergyNet_2019.pdf [Accessed 12th March 2021]. (In Russ.).

5. Bell K. R. W., Nedic D. P., Martin L. A. S. S. The need for interconnection reserve in a system with wind generation. *IEEE Transactions on Sustainable Energy*. 2012;3(4):703–712. <https://doi.org/10.1109/TSTE.2012.2208989>.

6. Chicco G., Riaz S., Mazza A., Mancarella P. Flexibility from distributed multienergy systems. In:

Proceedings of the IEEE. 2020;108(9):1496–1517. <https://doi.org/10.1109/JPROC.2020.2986378>.

7. Klyapovskiy S., You Shi, Michiorri A., Kariniotakis G., Bindner H.W. Incorporating flexibility options into distribution grid reinforcement planning: a techno-economic framework approach. *Applied Energy*. 2019;254:113662. <https://doi.org/10.1016/j.apenergy.2019.113662>.

8. Krč R., Kratochvilova M., Podroužek J., Apeltauer T., Stupka V., Pitner T. Machine learning-based node characterization for smart grid demand response flexibility assessment. *Sustainability*. 2021;13(5):2954. <https://doi.org/10.3390/su13052954>.

9. Förderer K., Ahrens M., Bao Kaibin, Mauser I., Schmeck H. Towards the modeling of flexibility using artificial neural networks in energy management and smart grids: note. In: *e-Energy '18: Proceedings of the Ninth International Conference on Future Energy Systems*. 12–15 June 2018, Karlsruhe. Karlsruhe; 2018, p. 85–90. <https://doi.org/10.1145/3208903.3208915>.

10. Förderer K., Ahrens M., Bao Kaibin, Mauser I., Schmeck H. Modeling flexibility using artificial neural networks. In: *Proceedings of the 7th DACH + Conference on Energy Informatics*. 2018;21:73–91. <https://doi.org/10.1186/s42162-018-0024-4>.

11. Hammami Z., Mouchaweh M. S., Mouelhi W., Said L. B. Discussion and review of the use of neural networks to improve the flexibility of smart grids in presence of distributed renewable resources. In: *17th IEEE International Conference on Machine Learning and Applications*. 17–20

December 2018, Orlando. Orlando: IEEE; 2018, p. 1304–1309. <https://doi.org/10.1109/ICMLA.2018.00211>.

12. MacDougall P., Kosek A. M., Bindner H., Deconinck G. Applying machine learning techniques for forecasting flexibility of virtual power plants. In: *IEEE Electrical Power and Energy Conference*. 2016. <https://doi.org/10.1109/EPEC.2016.7771738>.

13. Maruf M. N. I., Munoz L. A. H., Nguyen P. H., Ferreira H. M. L., Kling W. L. An enhancement of agent-based power supply-demand matching by using ANN-based forecaster. In: *4th IEEE PES Innovative Smart Grid Technologies Europe*. 2013. <https://doi.org/10.1109/ISGTEurope.2013.6695257>.

14. Coccia G., Mugnini A., Polonara F., Arteconi A. Artificial-neural-network-based model predictive control to exploit energy flexibility in multi-energy systems comprising district cooling. *Energy*. 2021;222. <https://doi.org/10.1016/j.energy.2021.119958>.

15. Baboli P. T., Babazadeh D., Bowatte D. R. K. Measurement-based modeling of smart grid dynamics: a digital twin approach. In: *10th Smart Grid Conference*. 2020. <https://doi.org/10.1109/SGC52076.2020.9335750>.

16. Glazunova A. M., Aksaeva E. S. Online estimation of flexibility of a power system that contains wind stations and energy storage units. *Elektroenergiya. Peredacha i raspredelenie*. 2021;3:24–31. (In Russ.).

17. Glazunova A., Aksaeva E., Semshikov E., Negnevitsky M. Determining the flexibility of power systems with high share of wind generation using artificial neural networks. In: *31st Australasian Universities Power Engineering Conference*. 2021. <https://doi.org/10.1109/AUPEC52110.2021.9597838>.

18. Aksaeva E. S., Glazunova A. M. The use of artificial neural networks under determination of electric power system flexibility. *Metodicheskie voprosy issledovaniya nadezhnosti bol'shih sistem energetiki. Nadezhnost' sistem energetiki v usloviyah ih cifrovizatsii: 93-e zasedanie seminara = Methodological issues of research of the reliability of large energy systems. Reliability of energy systems in terms of digitalization: 93rd meeting of the seminar*. 13–17 September 2021, Volzhskij. Volzhskij; 2021, p. 272–282. (In Russ.).

19. Parkhomenko S. S., Ledeneva T. M. Training of neural networks by the Levenberg–Marquardt method in conditions of a large amount of data. *Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyi analiz i informacionnye tehnologii = Proceedings of Voronezh State University. Series: Systems analysis and information technologies*. 2014;2:98–106.

20. Kohonen T. Self-organizing maps, 2008, 655 p. (Russ. ed.: *Samoorganizuyushchiesya karty*. Moscow, Binom. Laboratoriya znaniy; 2008, 655 p.)

ИНФОРМАЦИЯ ОБ АВТОРАХ

Аксаева Елена Сергеевна,
кандидат технических наук,
научный сотрудник Отдела
электроэнергетических систем,
Институт систем энергетики
им. Л.А. Мелентьева СО РАН,
664033, г. Иркутск, ул. Лермонтова, 130, Россия

Глазунова Анна Михайловна,
доктор технических наук, доцент,
старший научный сотрудник Отдела
электроэнергетических систем,
Институт систем энергетики им. Л.А.
Мелентьева СО РАН,
664033, г. Иркутск, ул. Лермонтова, 130, Россия

Вклад авторов

Все авторы сделали эквивалентный вклад в подготовку публикации.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Все авторы прочитали и одобрили окончательный вариант рукописи.

Информация о статье

Статья поступила в редакцию 18.01.2022; одобрена после рецензирования 21.03.2022; принята к публикации 01.06.2022.

INFORMATION ABOUT THE AUTHORS

Elena S. Aksaeva,
Cand. Sci. (Eng.),
Researcher the Department
of Electric Power Systems,
Melentiev Energy Systems Institute SB RAS,
130, Lermontov St., Irkutsk 664033, Russia

Anna M. Glazunova,
Dr. Sci. (Eng.), Associate Professor,
Senior Researcher of the Department
of Electric Power Systems,
Melentiev Energy Systems Institute SB RAS,
130, Lermontov St., Irkutsk 664033, Russia;

Contribution of the authors

The authors contributed equally to the preparation of the article.

Conflict of interests

The authors declare no conflict of interests.

The final manuscript has been read and approved by all the co-authors.

Information about the article

The article was submitted 18.01.2022; approved after reviewing 21.03.2022; accepted for publication 01.06.2022.