

Подтверждение конфигурации электрической сети по данным телеизмерений на основе сверточных нейронных сетей

МЯСНИКОВ Е.Ю., АНТОНОВ В.И., СОЛДАТОВ А.В., РАЗУМОВ Р.В.

Confirming of electrical network configurations based on television measurements based on convolutional neural networks

MYASNIKOV E.Yu., ANTONOV V.I., SOLDATOV A.V., RAZUMOV R.V.

Функция достоверизации конфигурации электрической сети является важной частью систем поддержки принятия решения и повышает надежность и эффективность управления режимом работы электрической сети. Классически функция реализуется на основе метода оценки состояния и не обладает должной скоростью реакции на изменения в электрической сети, а также требует больших вычислительных ресурсов. Между тем существуют современные инструменты, обеспечивающие высокую скорость реакции благодаря исключению расчетов режима электрической сети в реальном времени управления ею. К таким инструментам относятся нейронные сети. В статье предлагается система подтверждения конфигураций электрической сети на основе сверточных нейронных сетей. Исходными данными для нейронной сети являются телеизмерения режимных параметров, представленные в 2D-формате, а результатом являются локализованные ошибки в представлении текущей конфигурации электрической сети с оценкой уровня достоверности результата. Работа системы продемонстрирована на примере оценки конфигураций девятиузловой электрической схемы стандарта IEEE. Нейронная сеть демонстрирует высокую оперативность и точность распознавания текущей конфигурации, в том числе и в условиях искаженности и недостаточности данных телеизмерений.

Ключевые слова: электрические сети, телеизмерения, сверточные нейронные сети, достоверизация представления конфигурации электрической сети.

DOI: 10.53891/00135860-2024-8-8-16

Эффективное управление режимом работы энергосистемы подразумевает построение расчетной модели текущего режима и ее актуализацию в темпе реального времени. Современный взгляд на выполнение этой задачи предполагает

The reliability function of the electrical network configuration is an important part of decision support systems and increases the reliability and efficiency of managing the operating mode of the electrical network. Classically, the function is implemented on the basis of the condition assessment method and does not have the proper response rate to changes in the electrical network, and also requires large computing resources. Meanwhile, there are modern tools that ensure a high reaction rate due to the exclusion of calculations of the electrical network mode in real-time control of it. Such tools include neural networks. The article proposes a system for confirming electrical network configurations based on convolutional neural networks. The initial data for the neural network are tele-measurements of the operating parameters presented in 2D format, and the result is localized errors in the representation of the current configuration of the electrical network with an assessment of the level of reliability of the result. The operation of the system is demonstrated by the example of evaluating the configurations of a nine-node electrical circuit of the IEEE standard. The neural network demonstrates high efficiency and accuracy of recognition of the current configuration, including in conditions of distortion and insufficiency of tele-measurement data.

Key words: electrical networks, tele-measurements, convolutional neural networks, reliability of representation of the electrical network configuration.

ет применение различных интеллектуальных систем оценки состояния, систем поддержки принятия решения и цифровых двойников контролируемой электрической сети. В таких системах графическое представление электрической

сети традиционно формируется в виде однолинейной схемы, а актуализация ее конфигурации осуществляется преимущественно на основе телеметрических данных о состоянии коммутационных аппаратов. Между тем формирование актуальной конфигурации электрической сети на основе телеизмерений осложняется искажением информации о фактическом положении коммутационных аппаратов из-за шумов или потерь в данных. Разумеется, что ошибки в представлении конфигурации влияют на достоверность результатов работы различных приложений современных систем управления энергоснабжением, и должны быть оперативно устранены.

В связи с этим разработка средств достоверизации конфигурации электрической сети в режиме реального времени приобретает особую актуальность; статья посвящена решению этой задачи. Разрабатываемая в ней система подтверждения конфигурации контролируемой электрической сети, использующая развитый инструментальный сверточный нейронной сети, позиционируется как составная часть цифровой системы поддержки принятия решения или системы оценки состояния электрической сети и призвана повысить надежность управления энергосистемой.

Основные тенденции в развитии методов оценки топологии электрической сети

Для подтверждения конфигурации электрической сети и поныне применяются программные комплексы оценивания состояния электрических систем¹, использующие в своих алгоритмах телеизмерения и данные от SCADA-систем, а с недавних пор и от устройств синхронных векторных измерений [1]. Исправление грубых ошибок и восполнение недостающих измерений часто выполняется с помощью метода контрольных уравнений, являющегося по сути обобщением областей приложения законов Кирхгофа.

Из множества способов выявления несоответствий в представлении конфигурации электрической сети в качестве примера можно привести так называемый метод вычисления индексов корреляции [2]. Эти индексы определяют степень корреляции между данными, помечаемыми как возможно неверные из-за аномалии в конфигура-

ции, и данными, которые, как ожидается, будут реагировать на неправильную конфигурацию элементов сети. Эти индексы используются для ответа на вопрос: может ли быть вызвана обнаруженная аномалия любым из подозреваемых элементов конфигурации?

В то же время отчетливый тренд на внедрение интеллектуальных систем в практику управления электрической системой влияет и на выбор методов верификации топологии электрических сетей. Так, например, в [3, 4] рассматриваются методы, основанные на применении мультиагентной системы, взаимодействие агентов которой осуществляется на основе методов контрольных уравнений или методов оценки целевых показателей для узлов и ветвей электрической сети, называемых индексами дисбаланса. Второй метод развивает положения первого метода, также вычисляя рассматриваемые показатели по соотношениям, следующим непосредственно из законов Ома и Кирхгофа, и формируя из них характерный набор в ходе оценки конфигурации. Предполагается, что индексы дисбаланса принимают нулевое значение, когда конфигурация электрической системы не имеет ошибок, а телеизмерения не искажены. Верификация конфигурации включает в себя множество взаимозависимых самоорганизующихся подпроцессов, выполняющихся интеллектуальными агентами.

Другой разновидностью метода интеллектуального анализа, применяемого для подтверждения конфигурации электрической сети, является метод глубокого обучения на основе различных видов нейронных сетей [5]. При этом подразумевается, что применение синхронизированных векторных измерений повысит эффективность систем анализа конфигурации электрической сети благодаря росту информационной ценности данных, получаемых из электрической сети [6].

Предлагаемый в статье подход к верификации конфигурации электрической сети также основан на применении нейронных сетей и, как показывает вычислительный эксперимент, проявляет высокую эффективность выявления ошибок конфигурации сети в условиях зашумленности и искаженности данных телеизмерений [7, 8].

Постановка задачи

Задача достоверизации конфигурации электрической сети подразумевает распознавание актуальной схемы сети и выявление ошибочных представлений ее элементов на рабочем месте диспетчера в режиме реального времени. Информация о конфигурации сети представляется,

¹ Под оценкой состояния электрической системы традиционно понимается решение задачи расчета текущего режима. Это сугубо математический аспект постановки задачи порой приводит к путанице, поскольку операторы электрических сетей часто воспринимают ее как задачу оценивания состояния электрооборудования и самой сети.

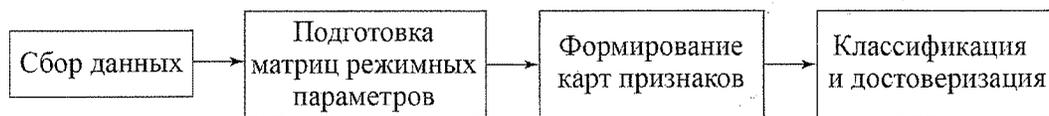


Рис. 1. Функциональная схема системы достоверизации конфигурации электрической сети

как правило, в виде совокупности связей между узлами и данных о статусе (включен/выключен) коммутационных аппаратов. Изменение статуса аппаратов и, следовательно, связей, так или иначе отражается на текущих режимных параметрах, таких, как напряжения узлов электрической системы и мощности в узлах и ветвях электрической схемы сети. Это свойство сети используется в решении задачи достоверизации конфигурации электрической сети.

Таким образом, под распознаванием актуальной схемы электрической сети в статье понимается выбор конфигурации, наиболее близкой к текущим измерениям режимных параметров из множества конфигураций, созданных на этапе настройки и обучения нейронной сети.

Централизованный сбор измерений режимных параметров может осуществляться с помощью SCADA-системы. Полученные информационные переменные с каждого узла электрической сети представляются в виде так называемых векторов измерений, приводятся к единому формату измерений путем нормализации и затем объединяются в матрицу режимных параметров, соответствующую актуальной конфигурации электрической сети.

Оперативная обработка матриц режимных параметров и выявление признаков, характеризующих текущую конфигурацию электрической сети, выполняется нейронной сетью. Представление о конфигурации электрической сети, полученной в результате работы нейронной сети, сравнивается с конфигурацией электрической сети, построенной на диспетчерском стенде согласно положению коммутационных аппаратов, в результате чего формируется вывод о её достоверности.

Систему достоверизации конфигурации электрической сети предлагается реализовать на основе программного комплекса, функциональная схема которого представлена на рис. 1.

Для иллюстрации положений статьи используется девятиузловая схема электрической сети стандарта IEEE, однолинейная схема которой приведена на рис. 2. Узлы электрической сети представлены шинами 1 – 9, связи между узлами 4 – 9 установлены линиями электропередачи, чьи статусы и отслеживаются системой достоверизации. Связи, представленные трансформаторами,

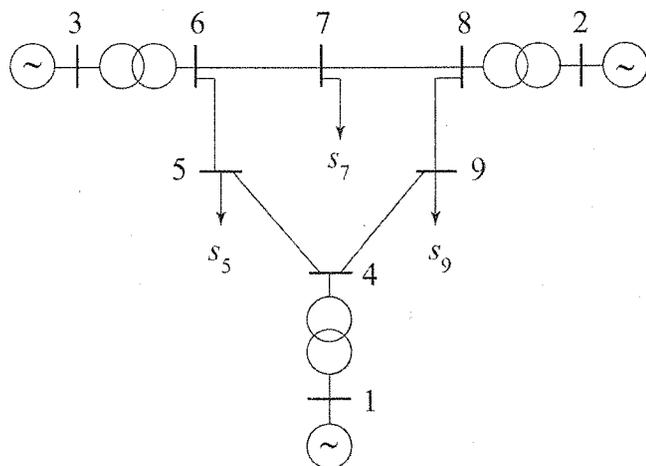


Рис. 2. Однолинейная схема девятиузловой электрической сети

в статье не рассматриваются, их состояние не отслеживается.

Сбор и подготовка данных

Предполагается, что системе достоверизации конфигурации доступны измерения активной $P_{n,m}$ и реактивной $Q_{n,m}$ мощностей линий и нагрузок в узлах (число измерений в каждом узле $2M_n, m = \overline{1, M_n}$), а также действующих значений напряжений U_n всех узлов ($n = \overline{1, N}$). Источником данных выбрана SCADA-система, объединяющая телеизмерения перечисленных параметров в вектор измерений для каждого узла электрической сети (рис. 3):

$$s_n^T = [U_n, P_{n,1}, \dots, P_{n,M_n}, Q_{n,1}, \dots, Q_{n,M_n}].$$

Количество присоединений M_n в узлах может отличаться, что отражается на длине $L_n = 2M_n + 1$ векторов измерений $s_n \in R^{L_n}$.

Векторы измерений s_n преобразуются в нормализованные векторы измерений x_n наибольшей длины $L = \max\{L_n\}$:

$$x_n \xleftarrow{L = \max\{L_n\}} s_n,$$

заменяя в них отсутствующие измерения нулями и приводя измерения – с целью повышения их информативности – к единому формату. При нормализации за базисные величины напряжения и мощности принимаются соответствующие номинальные параметры трансформатора с макси-

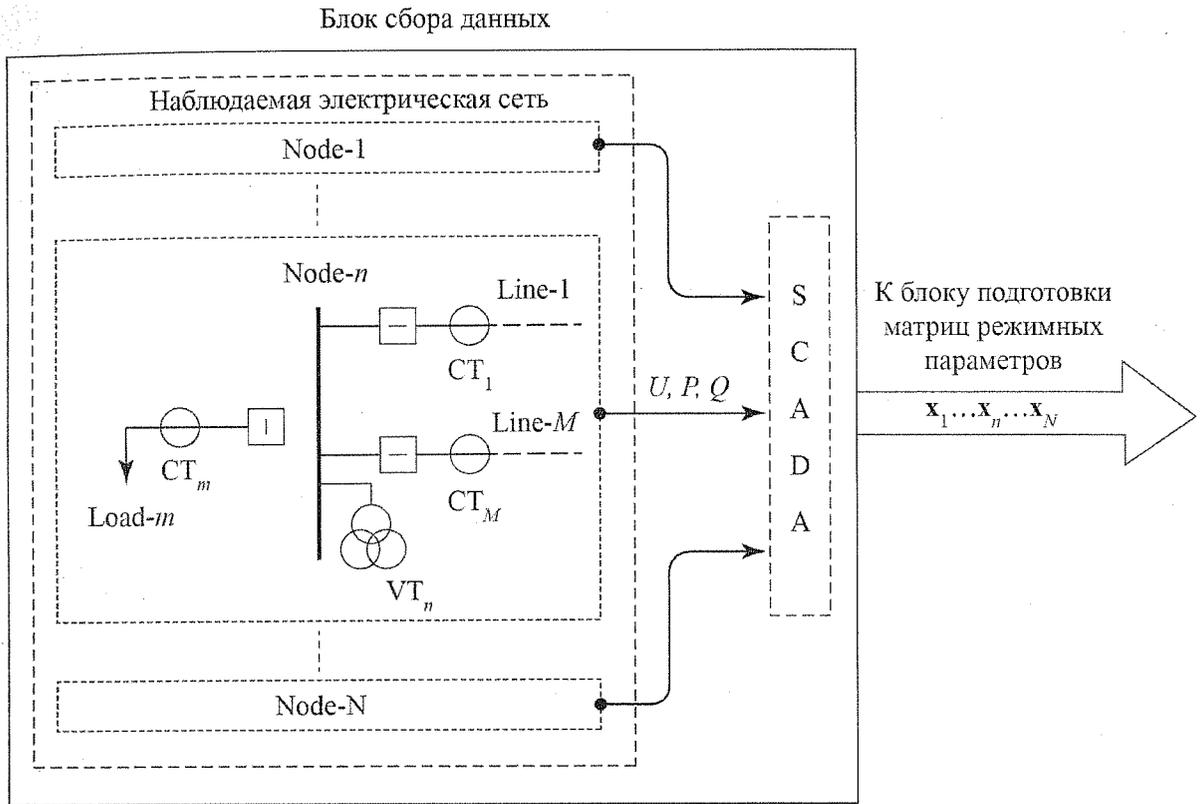


Рис. 3. Схема сбора данных

Блок подготовки матриц режимных параметров

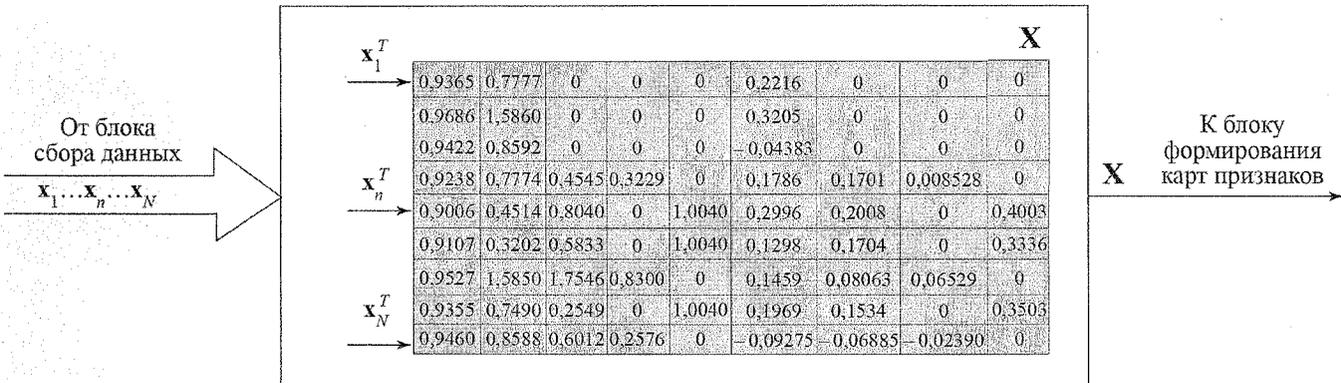


Рис. 4. Схема формирования актуальной матрицы режимных параметров

мальной мощностью. Полученные таким образом нормализованные векторы измерений образуют матрицу режимных параметров² контролируемой электрической сетью в текущий момент времени (рис. 4):

$$\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n, \dots, \mathbf{x}_N]^T \in R^{N \times L}. \quad (1)$$

² Часто эту матрицу формируют в виде двумерного изображения, каждая ячейка которого представляет собой оттенок цвета, соответствующий числовому значению ячейки в принятой шкале градации цвета. Поэтому в англоязычной литературе ее обычно называют Heatmap (Тепловая карта).

Сначала на стадии обучения нейронная сеть классифицирует конфигурацию сети под управлением учителя (разработчика) и формирует множество классов конфигураций. Затем, при эксплуатации в составе программного комплекса поддержки принятия решения, обученная нейронная сеть верифицирует актуальную конфигурацию электрической сети, представляемую на стенде диспетчера. Разница в работе нейронной сети в этих режимах заключается в том, что если при обучении нейронная сеть формирует представление о принадлежности конфигурации к тому или иному классу по реакции учителя, то

при работе в режиме наблюдения за электрической сетью поступающая к ней матрица режимных параметров (1) обрабатывается ею в режиме реального времени, и уже она сама выступает в роли арбитра, верифицируя и исправляя актуальную конфигурацию сети.

Формирование карт признаков

Система достоверизации конфигурации получает от SCADA-системы данные режимных параметров с заданной периодичностью, поэтому формируемую на их основе матрицу режимных параметров (1) можно трактовать как своего рода снимок текущей конфигурации электрической сети [9]. Как известно, анализ данных, представленных в формате изображений, успешно выполняют сверточные нейронные сети, которые легко выявляют важные области на анализируемом снимке (матрице режимных параметров) и формируют характерные карты признаков. При дальнейшем анализе определенной их совокупности в последующих слоях сверточной сети удастся установить (в режиме эксплуатации системы) или подтвердить (при обучении системы) принадлежность текущей конфигурации к одному из назначенных классов.

Блок формирования карт признаков состоит из трех слоев: входного, сверточного и слоя активации (рис. 5). Может показаться, что работа слоев не зависит от режима работы разрабатываемой системы, но это совсем не так. Действительно, в режиме обучения классы конфигурации уже определены разработчиком, поэтому сверточный слой и его фильтры W_k будут согласованы с классом конфигураций

обучающей выборки. Но уже в режиме эксплуатации сверточный слой формируется в результате выполнения множества операций свертки матрицы режимных параметров X с настроенными при обучении фильтрами W_k .

Задача свертки сводится к извлечению признаков из матрицы режимных параметров X с помощью двумерных фильтров $W_k \in R^{3 \times 3}$. Число предусмотренных признаков K определяет количество необходимых фильтров W_k ; в данной работе число признаков ограничено и равно 32, то есть $K = 32$.

Каждый фильтр W_k создает собственную карту признаков, значения элементов которой определяются сверткой:

$$y'_k(p, q) = \text{tr}[\chi(i, j)W_k^T] + b_k, \quad (2)$$

$$(p = \overline{1, P}; q = \overline{1, Q}),$$

где $p = i - 1$ и $q = j - 1$ – номер ячейки карты признаков Y_k , в которой сохраняется результат свертки k -го фильтра W_k с его полем восприятия $\chi(i, j)$ на матрице режимных параметров с центром с координатами (i, j) ;

tr – функция вычисления следа матрицы;
 b_k – коэффициент смещения k -го канала.

Значения элементов карты признаков зависят от степени корреляции между весами фильтра W_k и данными, оказавшимися в его поле восприятия $\chi(i, j)$, и могут быть положительными или отрицательными. В силу свойств фильтров считается, что элементы с положительными знаками обладают преимуществом в представлении признаков, в связи с чем все элементы карт признаков

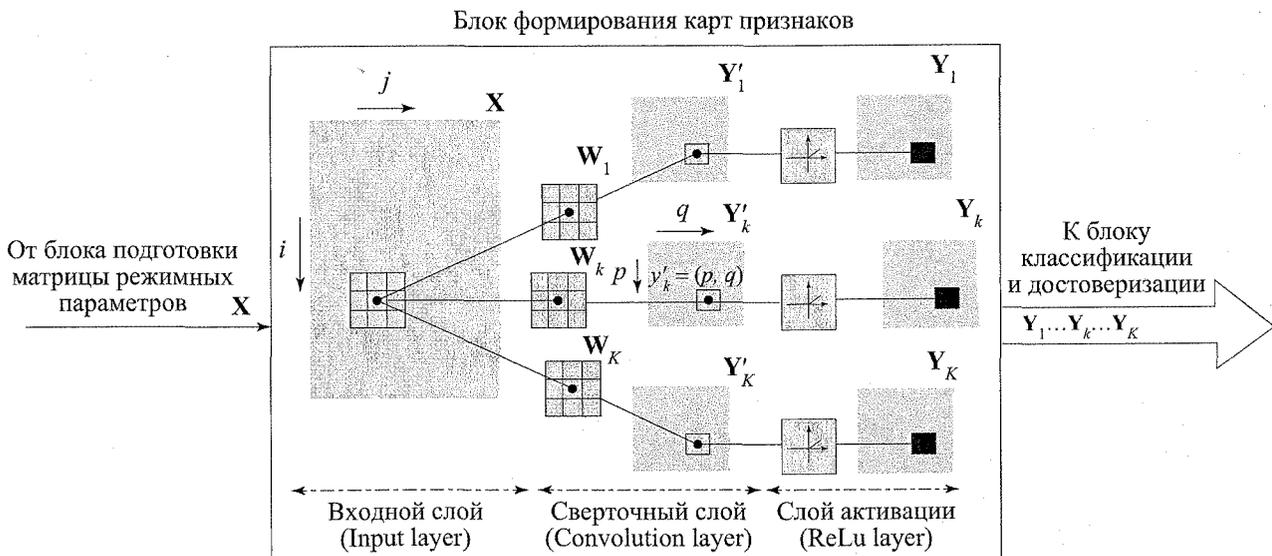


Рис. 5. Схема формирования карт признаков

подвергаются так называемой операции активации с целью исключения малоинформативных элементов.

В разрабатываемой сверточной сети активации состоит из функций активации $ReLU$, которая имеет множество вариаций применения, главным образом связанных с решением проблем учета вклада активируемого элемента с отрицательным знаком [10]. Вычислительный эксперимент показал, что функция $ReLU$ в её классическом представлении:

$$f_{ReLU}(y') \begin{cases} y' & y' > 0; \\ 0, & y' \leq 0, \end{cases}$$

в котором отрицательные признаки относятся к малоинформативным и заменяются нулевыми значениями, обеспечивает удовлетворительную точность классификации топологии рассматриваемой электрической сети.

В обычной практике применения сверточных сетей после слоя активации используют слой пулинга для повышения контраста между различными областями карты признаков и уменьшения размера полносвязного слоя. Вычислительный эксперимент показал, что при анализе топологии электрической сети рассматриваемого примера (рис. 2) слой пулинга не оказывает значимого положительного влияния на работу нейронной сети, в связи с чем резонность его применения была поставлена под сомнение.

Нормализация карт признаков

Множество измерений электрических величин в электрической сети одной и той же конфигурации различаются по уровню, что приводит к вариации пропорций между элементами карты признаков и так называемому ковариантному сдвигу [11]. Это свойство нейронной сети приводит к ухудшению сходимости моделей и темпа обучения. Для того, чтобы исключить влияние уровня измеряемых электрических величин на качество обучения прибегают к нормализации элементов карт признаков.

Наиболее практичным способом регуляризации сверточной нейронной сети считается пакетная нормализация карты признаков [11]. В рассматриваемой системе на каждом ее шаге нормализуется пакет, включающий в себя вектор-столбец $y_{k,q}$ карты признака $Y_k (k = 1, K)$:

$$\hat{y}_{k,q} = \frac{y_{k,q} - \mu_{k,q}}{\sqrt{\sigma_{k,q}^2 + \varepsilon}},$$

где $\mu_{k,q}$ и $\sigma_{k,q}$ – математическое ожидание и дисперсия признаков по обрабатываемому пакету, константа регуляризации ε принята равной 10^{-5} .

Предпринятая нормализация может изменить представление признаков. Во избежание этого влияния на последующем шаге выполняется линейное преобразование пакета с параметрами сжатия $\gamma_{k,q}$ и сдвига $\beta_{k,q}$:

$$\mathbf{z}_{k,q} = \gamma_{k,q} \hat{\mathbf{y}}_{k,q} + \beta_{k,q}.$$

Параметры $\gamma_{k,q}$ и $\beta_{k,q}$ настраиваются в ходе обучения вместе со всеми параметрами представления конфигурации.

Полученная нормализованная карта не теряет точности представления признаков и способствует высокой динамике сходимости обучения.

При работе обученной нейронной сети в составе системы достоверизации нормализация карт признаков осуществляется на основе фиксированных значений математического ожидания и дисперсии, полученных как среднее всех математических ожиданий и дисперсий по всем пакетам обучения.

Классификация признаков

В рассматриваемой нейронной сети роль классификатора отведена полносвязному слою. Источником его входных данных является слой нормализации; при этом все векторы – столбцы $\mathbf{z}_{k,q}$ матриц нормализованных признаков $\mathbf{Z}_k (k = \overline{1, K})$ разворачиваются в единый вектор входных данных по следующему правилу (рис. 6):

$$\boldsymbol{\zeta} = [\zeta_1 \dots \zeta_k \dots \zeta_K], \quad (3)$$

где $\zeta_k = [\mathbf{z}_{k,1}^T \dots \mathbf{z}_{k,q}^T \dots \mathbf{z}_{k,Q}^T]$ – вектор-строка, созданная последовательной конкатенацией столбцов матрицы нормализованных признаков \mathbf{Z}_k . В данном случае размер входного вектора $\boldsymbol{\zeta}$ будет равен $S = P \times Q \times C = 7 \times 7 \times 64 = 3136$.

Число нейронов в полносвязном слое принято равным размеру множества классов распознаваемых конфигураций C ; в данном примере $C = 64$. Вектор выходных данных нейронов полносвязного слоя:

$$\mathbf{p} = [p_1, \dots, p_c, \dots, p_C]^T$$

формируется как результат взвешивания единого вектора (3) матрицей весов входов нейронов $\Phi \in R^{C \times S}$:

$$\mathbf{p} = \Phi \boldsymbol{\zeta} + \boldsymbol{\beta}, \quad (4)$$

где $\boldsymbol{\beta}$ – вектор коэффициентов смещения.

В выходном слое сначала оценивается степень принадлежности текущей конфигурации электрической сети каждому из предусмотренных классов конфигураций. С этой целью формируется оценка вероятности отнесения текущей конфигурации к каждому из предусмотренных классов конфигурации, полагая, что суммарная вероятность принадлежности ко всем классам равна единице. Используется функция активации SoftMax, формирующая вероятность принадлежности текущей конфигурации к классу с номером $c \in C$:

$$\sigma_c = \frac{e^{p_c}}{\sum_{n=1}^C e^{p_n}}$$

Затем результат работы слоя активации SoftMax толкуют как оценку точности определения конфигураций электрической сети и объявляют искомым результатом работы сети конфигурацию, принадлежащую классу с максимальной вероятностью:

$$\sigma_{\max} = \max \{ \sigma_1, \sigma_2, \dots, \sigma_C \}.$$

Обучение сверточной сети

Проектируемая нейронная сеть реализуется на основе инструментов библиотеки Deep Learning программной среды MATLAB, при обучении сети используется метод стохастического градиентного спуска с инерцией (Stochastic Gradient Descent with Momentum – SGDm). Структурная схема проектируемой сверточной сети состоит из каскада блоков (рис. 2 – 6).

При обучении сверточной сети учитель (разработчик) обозначает класс текущей конфигурации и соответствующую ей матрицу режимных параметров X . Среда обучения в конце каждого этапа обучения сверточной сети измеряет близость оценки конфигурации к обозначенному классу и в зависимости от ее результата выполняет корректировку параметров сверточной сети методом обратного распространения ошибки. Процесс обучения повторяется до достижения желаемого качества обучения нейронной сети в пределах заданного числа этапов обучения.

Обучающая выборка в виде множества матриц режимных параметров X , снабженных дискриминантами принадлежности к определенному классу конфигурации электрической сети, формируется путем имитационного моделирования девятиузловой схемы (рис. 4) в программном комплексе для моделирования энергосистем PSCAD. Достижение необходимого качества обучения поддерживается включением в план имитацион-

ного моделирования широкого круга установившихся режимов электрической сети для каждого из вариантов её конфигурации. Подходящего разнообразия режимов работы добиваются, меняя случайным образом узловые нагрузки и уровни генераторного напряжения в регламентированных диапазонах.

Для рассматриваемой электрической схемы формируется перечень классов, охватывающий все возможные конфигурации. Топология каждой конфигурации определяется как топология определенного класса и зависит от положения коммутационных аппаратов связей. Число связей определяет максимальное количество возможных конфигураций электрической сети, которое в случае девятиузловой схемы составляет $C = 2^6 = 64$.

Как отмечалось, для каждой топологии электрической сети в ходе моделирования формируется обучающая выборка из набора матриц режимных параметров. Вычислительный эксперимент показывает, что для девятиузловой схемы достаточно обучающая выборка, состоящая из набора 120 матриц режимных параметров X для каждого класса конфигурации.

Тестирование классификатора

Качество обучения и правильность работы сверточной сети оцениваются на тестовом наборе матриц режимных параметров для каждой конфигурации электрической сети; тестовый набор не должен повторять данные обучающей выборки. Для проверки устойчивости системы к искажениям в измерениях часть данных тестового набора случайным образом намеренно повреждается путем обнуления некоторых данных или добавлением к ним шума с уровнем до 10-й части самого измерения.

Настроенная нейронная сеть формирует решение в формате таблицы, пример которой приведен в табл. 1, в которой показано сообщение нейронной сети при оценке ею конфигурации с отключенными линиями связи между узлами 4 – 9 и 5 – 6 (включенному или отключенному состояниям коммутационных аппаратов соответствуют сигналы «1» или «0»).

Таблица 1

Пример работы нейронной сети

Имя класса	Точность	Состояние линий					
		4 – 5	4 – 9	5 – 6	6 – 7	7 – 8	8 – 9
Класс 39	99,88 %	1	0	0	1	1	1

Уровень достоверности оценки конфигурации контролируется с помощью порога доверия; результаты работы нейронной сети с точностью

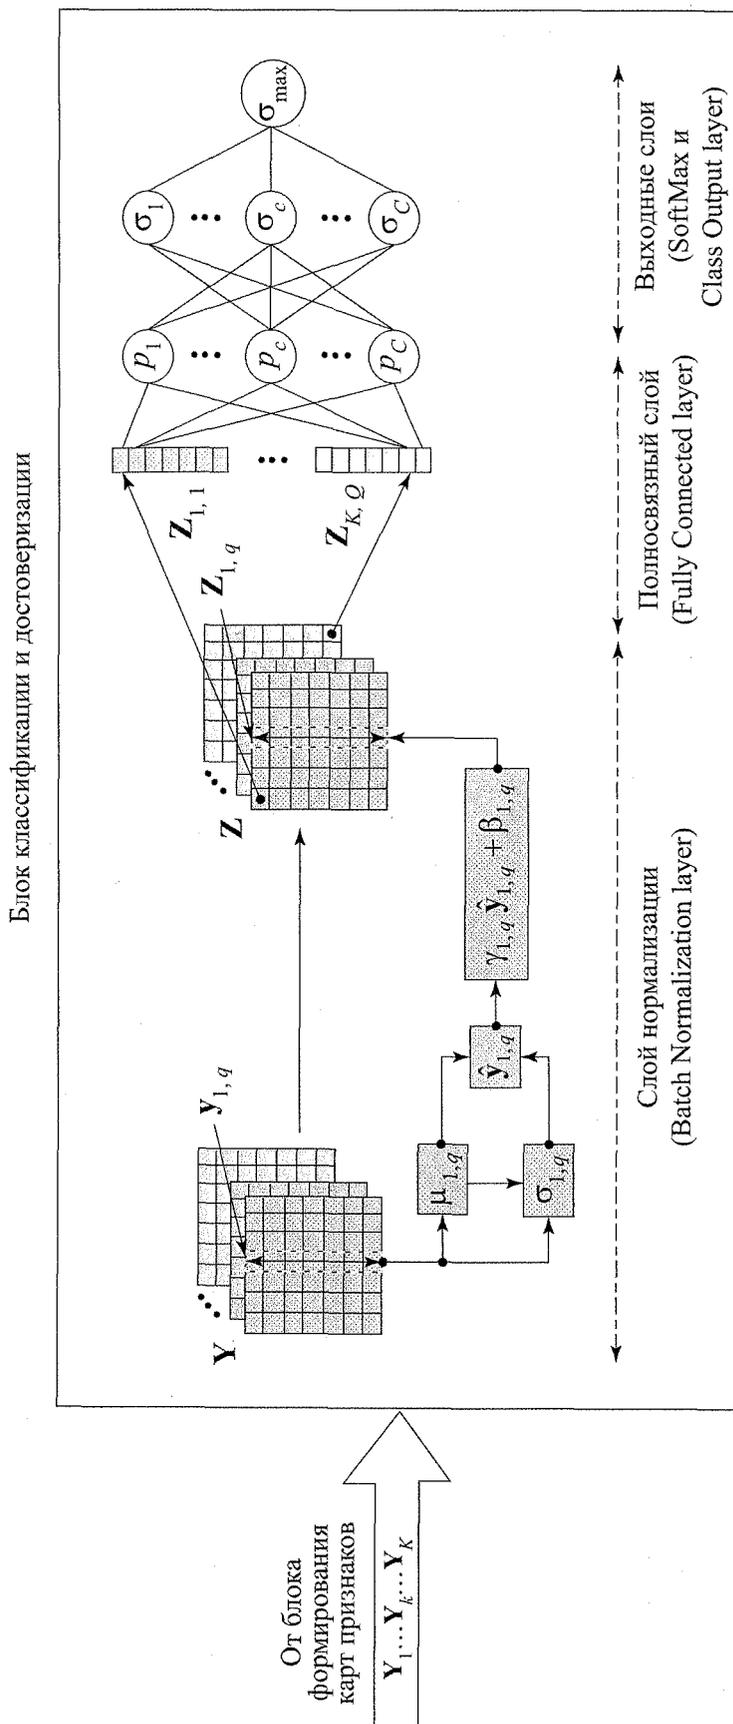


Рис. 6. Схема работы слоев нормализации и классификации

ниже него отбрасываются и выдаются сигналы о недостоверности оценок. Средние значения точности оценки топологии электрической сети каждого типа конфигурации при тестировании проектируемой нейронной сети приведены в табл. 2. Как показало тестирование системы на девятиузловой схеме, показатель точности оценки конфигурации, разработанной нейронной сетью, не опускается ниже 99 %.

Таблица 2

Результаты тестирования

Тип конфигурации	Средняя точность определения конфигурации, %	
	Тестовые данные без шума	Тестовые данные с шумом и повреждениями
Все линии включены	100,00	100,00
Отключена 1 линия	99,32	99,21
Отключены 2 линии	99,65	99,45
Отключены 3 линии	99,59	99,40
Отключены 4 линии	99,77	99,63
Отключены 5 линий	99,96	99,85

Выводы

1. Сверточная нейронная сеть оценивает топологию текущей конфигурации электрической сети надежно и с достаточно высоким порогом доверия. Это открывает возможность контролировать достоверность актуальной конфигурации на стенде диспетчера и исправлять ошибки в представлении топологии в режиме реального времени. Такая оперативность системы достоверизации конфигурации достигается за счет обучения нейронной сети на множестве данных, полученных, например, в результате имитационного моделирования режимов работы электрической сети.

2. Источником данных о текущем режиме электрической сети является SCADA-система, предоставляющая информацию в режиме реального времени. Разработанная сверточная нейронная сеть не предъявляет специфических требований к входному интерфейсу данных и, как показывает вычислительный эксперимент, обнаруживает робастность к искажению входных данных.

Данная работа финансировалась за счет средств от приносящей доход деятельности ФГБОУ ВО «ЧГУ им. И.Н. Ульянова». Никаких дополнительных грантов на проведение или руководство данным конкретным исследованием получено не было.

This work was funded by funds from the income-generating activities of the I.N. Ulyanov Chuvash State University. No additional grants to carry out or direct this particular research were obtained.

Авторы данной работы заявляют, что у них нет конфликта интересов.

The authors of this work declare that they have no conflicts of interest.

Список литературы

1. Колосок И.Н., Коркина Е.С., Суханова О.А. Алгоритмы распределенного оценивания состояния больших энергосистем // Электричество. 2011. № 4.
2. Costa A.S., Leao J.A. Identification of Topology Errors in Power System State Estimation // IEEE Transactions of Power Systems. 1993. № 4 (8).
3. Массель Л.В., Гальперов В.И. Разработка многоагентных систем распределенного решения энергетических задач с использованием агентных сценариев // Известия Томского политехнич. ун-та. Инжиниринг георесурсов. 2015. Т. 326. № 5.
4. Wilkosz K., Lukomski R. Power System Topology Verification using Network Examinations and Artificial Neural Networks // Electric Power Engineering. 2006.
5. Готман Н.Э., Шумилова Г.П. Идентификация изменения состояния линии по векторным измерениям на основе сетей глубокого обучения // Проблемы энергетики. 2020. № 6.
6. Готман Н.Э., Шумилова Г.П., Старцева Т.Б. Определение топологии электрической сети при делении ее на участки с привязкой к устройствам PMU / Методологические проблемы исследования надежности крупных энергетических систем. Материалы междунар. конф. Руденко, 2016.
7. Gupta A. Gurralla G. An Online Power System Stability Monitoring System Using Convolutional Neural Network / IEEE Transactions of Power Systems, 2018.
8. Мясников Е.Ю. Перспективы применения нейронных сетей в решении задач электроэнергетики / Проблемы и перспективы развития энергетики, электротехники и энергоэффективности. Материалы IV Междунар. научно-технич. конф., 2020.
9. Мясников Е.Ю., Антонов В.И., Наумов В.А. Верификация конфигурации электрической сети на основе сверточных нейронных сетей / Информационные технологии в электротехнике и электроэнергетике. Материалы XII Всерос. научно-технич. конф., 2022.
10. Han J., Wang Z., Huajin S. Tang Symmetric-threshold ReLu for Fast and Nearly Lossless ANN-SNN Conversion // Machine Intelligence Research. 2023. Vol. 20. № 3.
11. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. 2015.