

УДК 004.8: 621.315.23

СИСТЕМА ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ОНЛАЙН-МОНИТОРИНГА ПОДЗЕМНЫХ СИЛОВЫХ КАБЕЛЬНЫХ ЛИНИЙ НА ОСНОВЕ ТЕХНОЛОГИЙ ГЛУБОКОГО ОБУЧЕНИЯ

Верзунов С.Н., к.т.н., verzunov@hotmail.com

Институт машиноведения и автоматики НАН КР, Бишкек, Кыргызская Республика

В работе описана система искусственного интеллекта для обнаружения, классификации и локализации неисправностей в трехфазной силовой подземной кабельной линии среднего напряжения с использованием глубоких нейронных сетей на основе CNN и LSTM моделей, использующая специализированное программное обеспечение для получения большого набора данных для обучения глубоких нейронных сетей, и изложена процедура подготовки данных, необходимых для обучения

Ключевые слова: кабельная линия, мониторинг, глубокое обучение, CNN, LSTM

Введение. Подземные кабельные сети в современных городах получили широкое распространение благодаря их многочисленным преимуществам. В то же время из-за их конструктивных особенностей часто оказывается невозможным локализовать возникающие неисправности путем визуального осмотра. Решить эту проблему позволила бы система мониторинга неисправностей в режиме реального времени для их обнаружения и классификации. Такая система может быть основана, например, на применении метода кривых Лиссажу [1] и использовании машины опорных векторов, одного из методов поверхностного машинного обучения для классификации неисправностей. Известно большое количество работ, посвященных системам классификации и обнаружения неисправностей, возникающих в системе передачи, например [2, 3], основанных на схожих принципах.

Рекуррентные нейронные сети, широко используемые для обработки временных рядов, обрабатывают элементы ряда последовательно, с применением информации, полученной при обработке предыдущих его элементов, также могут использоваться в таких системах. Кроме рекуррентных нейронных сетей, для обработки временных рядов можно использовать сверточные нейронные сети (Convolutional Neural Network, CNN) благодаря их способности к свертыванию параметров, извлечению признаков из локальных входных шаблонов, получению эффективных и модульных представлений данных. Объединение одномерной CNN и сети LSTM позволяет сочетать преимущества обоих методов глубокого обучения, что показано в работах [4, 5, 6], в которых гибридные CNN-LSTM сети превзошли альтернативные технологии машинного обучения в решении некоторых задач классификации и регрессии. Однако в области локализации повреждений в подземных кабельных линиях эти технологии глубокого обучения пока еще не нашли широкого применения.

Цель настоящей работы – разработать систему искусственного интеллекта (СИИ) для обнаружения, классификации и локализации неисправностей в трехфазной силовой подземной кабельной линии среднего напряжения с использованием глубоких нейронных сетей на основе CNN и LSTM моделей.

Задачами настоящей работы являются:

– моделирование неисправностей подземных силовых кабельных линий с использованием специализированного программного обеспечения PSCAD/EMTDC (<https://www.pscad.com/>) для получения большого набора данных для обучения глубоких нейронных сетей и разработка способа предварительной обработки полученных данных;

– разработка архитектур глубоких нейронных сетей, входящих в состав предлагаемой СИИ.

– оценка точности определения неисправностей с помощью обученных нейронных сетей.

Моделирование подземной кабельной линии. Рассмотрим, например, процесс, сопровождающий возникновение короткого замыкания в подземной кабельной линии. Построим имитационную модель этой линии (рис. 1) в PSCAD/EMTDC, состоящую из трехфазного неразветвленного кабеля. Данное программное обеспечение позволяет задать рабочее напряжение, частоту, материал, сечение кабеля и параметры нагрузки, такие, как, например, ее активная и реактивная мощность. С помощью этой модели можно имитировать 10 различных неисправностей (см. табл.1), например, трехфазное замыкание на землю (ФФЗ), замыкание одной из фаз на землю (ФЗ), межфазное замыкание (ФФ), межфазное замыкание на землю (ФФЗ) с различными условиями возникновения неисправности для того, чтобы получить большой набор данных для обучения глубоких нейронных сетей.



Рисунок 1 – Схема подземной кабельной линии

Генерирование данных. Точность работы любой СИИ очень сильно зависит от качества и количества образцов в обучающем наборе данных. Для того чтобы получить статистически значимый набор данных, все параметры рассматриваемой модели варьируются в некоторых пределах, и для каждой возможной комбинации генерируется соответствующая выборка данных. Это позволяет получить достаточное количество разнообразных данных для обучения нейронных сетей. Пусть, например, неисправность возникает в интервале времени моделирования $t=200-220$ мс в зависимости от заданной фазы напряжения, а предохранитель срабатывает через 150 мс после возникновения короткого замыкания. Генерируется два набора данных: первый для обнаружения и классификации неисправности, а второй для локализации неисправностей. Параметры модели, используемые для генерации данных, приведены в таблице 1.

Таблица 1 – Параметры модели, используемые для генерации наборов данных

Параметр модели	Значения параметров для первого набора данных	Значения параметров для второго набора данных
Фаза напряжения при возникновении неисправности, градусы	0, 18, 36, 54,.....288, 306, 324, 342	0, 36, 72, 108, 144, 160, 192, 228, 324
Импеданс короткого замыкания, Ом	0.01, 0.1, 1, 5, 10, 15	0.01, 1, 5, 10
Тип неисправности	ФЗ(А3, Б3, В3), ФФЗ(АБ3, БВ3, АВ3, АБВ3, ФФ(АБ, БВ, АВ),	ФЗ (А3, Б3, В3)
Местоположение (удаление от источника) неисправности, км	2, 4, 6, 8, 10, 12, 14, 16, 18, 20	0.2, 0.4, 0.6, 0.8,.....19.4, 19.6, 19.8, 20

Значения параметров, приведенных в таблице 1, должны быть выбраны таким образом, чтобы с определенным шагом перекрывать значения, которые могут встретиться в реальных условиях, так как обученные нейронные сети могут правильно распознать и обработать только такие входные данные, встречавшиеся в обучающей выборке.

Таким образом, при использовании всех возможных комбинаций значений параметров модели генерируется 12000 выборок данных. Все сгенерированные данные имеют частоту дискретизации 8 кГц. Для имитации реальных условий добавляется аддитивный белый гауссовский шум с отношением сигнал/шум от 20 до 60 дБ, его амплитуда выбирается случайным образом для каждого образца в наборах данных. Из сгенерированных выборок с помощью скользящего окна вырезаются участки шириной 100 мс для формирования двух наборов данных – для сетей, отвечающих за классификацию и локализацию неисправностей. Затем наборы данных случайным образом перемешиваются и разделяются в отношении 5:1 для обучения и проверки работы глубоких нейронных сетей.

Архитектура предлагаемой СИИ. Для решения поставленной задачи предлагается использовать глубокие нейронные сети, основанные на комбинации одномерных сверточных сетях Conv-1D и LSTM-сетях для классификации и локализации неисправностей в подземных кабельных линиях.

Выход Conv-1D сети h_c после операции свертки, может быть описан формулой:

$$h_c(c_i) = b(c_i) + \sum_{j=0}^{l_c-1} w(c_i, j) \odot x(j) \quad (1)$$

где x – входной тензор, w – матрица весов, b – вектор смещения, c_i – i -й выходной канал; l_c – размерность входа; \odot – оператор, означающий кросс-корреляцию.

К результату свертки затем применяется нелинейная функция активации, такая, как, например, ReLU, и результат преобразуется с помощью операции одномерного пулинга (снижение разрешения входной последовательности путем взятия максимального значения h_p из соседних в обрабатываемой последовательности):

$$h_p(c_i, j) = \max_{m=0, \dots, l_k-1} h_c(c_i, (l_s * j) + m), \quad (2)$$

где l_k и l_s означают длину ядра пулинга и длину шага соответственно.

Далее результат преобразуется в вектор и передается в рекуррентную LSTM-сеть. В рекуррентных нейронных сетях для реализации обратной связи используется комбинация скрытого состояния на предыдущем шаге и текущих входных данных в слое с нелинейной функцией активации, например, такой, как гиперболический тангенс. В LSTM-сети обратная связь реализуется аналогично, но нейронных слоев используется не один, а четыре. Скрытое состояние LSTM-сети h_t в момент t по состоянию h_{t-1} на предыдущем шаге находится по формулам:

$$i = \sigma(W_t h_{t-1} + U_t x_t), \quad (3)$$

$$f = \sigma(W_f h_{t-1} + U_f x_t), \quad (4)$$

$$o = \sigma(W_o h_{t-1} + U_o x_t), \quad (5)$$

$$g = th(W_g h_{t-1} + U_g x_t), \quad (6)$$

$$c_t = (c_{t-1} \otimes f) \oplus (g \otimes i), \quad (7)$$

$$h_t = th(c_t) \otimes o. \quad (8)$$

Здесь i , f и o – векторы, называемые входной вентиль, вентиль забывания и выходной вентиль, а операторы \otimes , \oplus – тензорное произведение и сумма соответственно. Все они вы-

числяются по одним и тем же формулам, но разными матрицами весов W_i , W_f , W_o и U_i , U_f , U_o . Сигмовидная функция σ модулирует выход вентиля, приводя его к диапазону от 0 до 1, так что порождаемый выходной вектор можно умножить поэлементно на другой вектор, чтобы определить, какая часть второго вектора может пройти через первый. Вентиль забывания определяет, какую часть предыдущего состояния h_{t-1} желательно пропустить дальше. Входной вентиль определяет, какую часть внутреннего состояния передать следующему слою. Внутреннее скрытое состояние g вычисляется на основе текущего входа x_t и предыдущего скрытого состояния h_{t-1} . Зная i , f , o и g , можно вычислить состояние ячейки c_t в момент t как сумму произведений c_{t-1} на вентиль f и g на входной вентиль i . Наконец, скрытое состояние h_t в момент t вычисляется путем умножения памяти c_t на значение выходного вентиля [7].

В целом СИИ для обнаружения, локализации и классификации неисправностей с применением предобработки скользящим окном показана на рис. 2. В процессе работы системы мгновенные значения токов и напряжений сохраняются в буфере соответствующего размера. Скользящее окно требуется для того, чтобы уменьшить длину данных на входе нейронной сети, разбив многомерные входные данные напряжения и тока на более мелкие фрагменты, которые можно быстро обработать с помощью нейронных сетей.

Возьмем для определенности скользящее окно длиной в 800 отсчетов (100 мс). Сеть для классификации неисправностей использует, в отличие от сети, описанной в работе [8], трехмерные сигналы тока и напряжения, также как и сеть для определения местоположения неисправности, измеряемые со стороны источника с помощью специальных высоковольтных измерительных средств. Таким образом, окно размером 6×800 «перемещается» по сигналу (рис. 2), сохраненному в буфере, и каждый участок передается в первую сеть для классификации неисправности, имеющую два выхода, соответствующих определенной неисправности и времени ее возникновения.

Если прогнозируемый класс неисправности не соответствует классу «исправно», то используется вторая сеть для локализации неисправности (ФЗ, ФФ, ФФЗ, ФФФ). Окно размером 6×800 с трехмерными сигналами тока и соответствующими сигналами напряжения передается во вторую сеть для определения местоположения неисправности, имеющую один выход, соответствующий расстоянию до места возникновения неисправности. В онлайн-системе мониторинга этот процесс повторяется бесконечно (рис.2), где текущее окно обозначается как w_t , включающее данные между текущим временным шагом $t-799$ и t включительно. После того, как сети обработают эти данные, процесс повторяется для следующего окна w_{t+1} , содержащего данные между временным шагом $t-798$ и $t+1$ включительно. Постобработка результатов необходима для получения окончательной оценки времени возникновения, типа и местоположения неисправности из множества выходных данных, генерируемых по нескольким окнам.

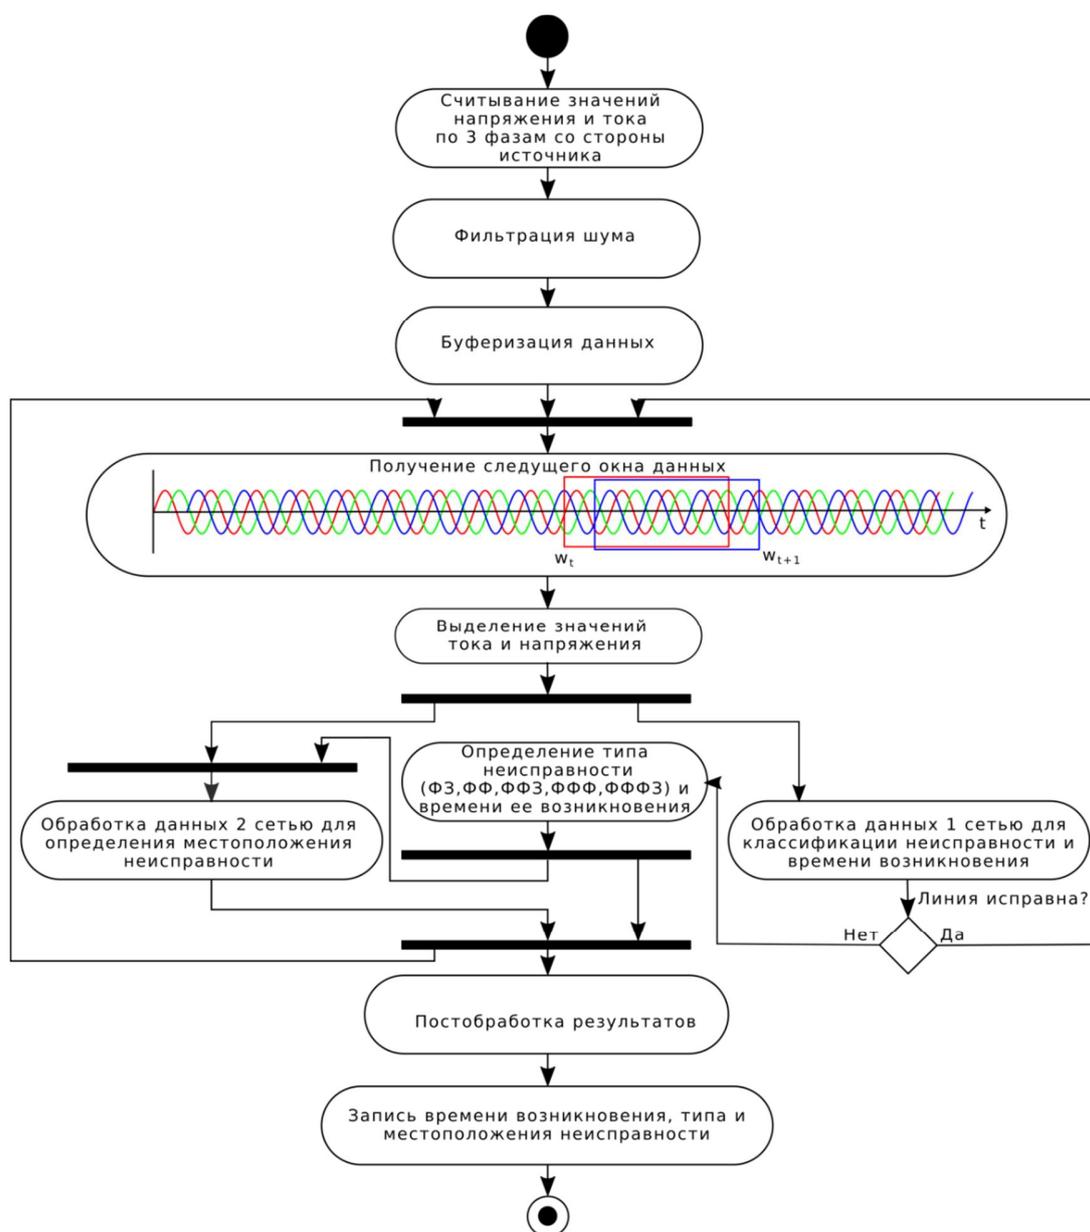


Рисунок 2 – Схема работы предлагаемой системы мониторинга

Для окон, не содержащих данные о возникновении неисправности, первая сеть должна возвращать ноль, для остальных окон должен возвращаться номер отсчета, соответствующий времени начала неисправности, относительно начала окна – целое число от 1 до 800. Тогда время возникновения неисправности тогда может быть вычислено как:

$$t(w_i) = t_i + \frac{t_i - 799}{f_s} t_f \neq 0 \quad (9)$$

где t_f – номер отсчета, соответствующий возникновению неисправности и f_s – частота дискретизации. Среднее всех полученных значений и используется для окончательной оценки времени возникновения неисправности.

Тип неисправности будет оставаться постоянным большую часть времени, однако может колебаться в окнах, где происходит переход между различными возможными значениями. Чтобы избавиться от подобной неопределенности, необходимо выбрать класс, возникающий наибольшее количество раз после предполагаемого начала неисправности. Местоположение неисправности определяется только для окон данных, определенных как содержащие информацию о неисправности. Среднее значение всех полученных на выходе сети значений используется для получения окончательной оценки расстояния до места возникновения неисправности.

Архитектура глубокой нейронной сети для определения типа неисправности. На рис. 3 показана возможная архитектура нейронной сети для обнаружения и классификации

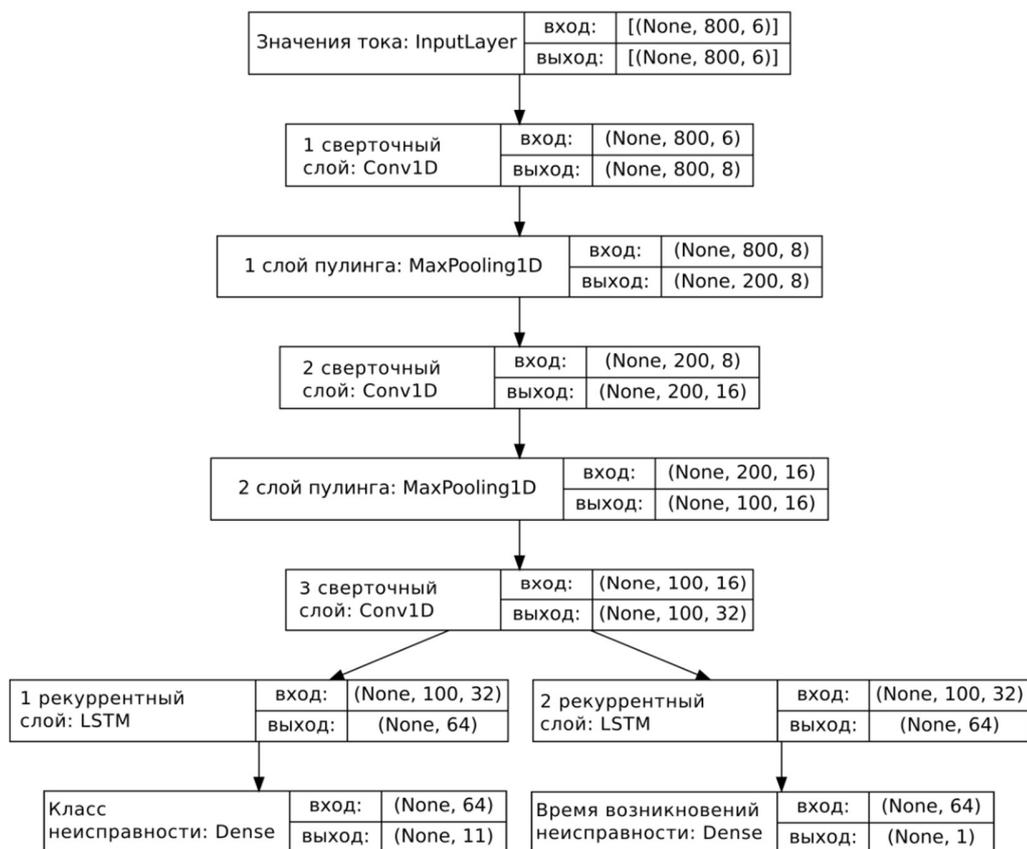


Рисунок 3 – Архитектура глубокой нейронной сети для определения класса неисправности и времени ее возникновения

неисправностей в подземной кабельной линии. Помимо 10 типов возможных неисправностей, имеется дополнительный класс «исправно» для предотвращения появления случайных выходных значений сети при отсутствии неисправности. По сравнению с определением местоположения неисправности, их классификация является более простой задачей. Но для повышения точности эта сеть использует и значения тока и напряжения. Чтобы получить набор данных для этой сети, окно размером 100 мс скользит по каждой выборке данных, и для каждой выборки вырезаются два участка. Обрезка выполняется таким образом, чтобы в результате получилось не менее 20 % данных после возникновения неисправно-

сти. Должно получиться 24000 образцов по 2400 на каждый тип неисправности. Образцы, соответствующие классу «исправно», можно получить путем случайной обрезки участков с менее чем 20 % данных после возникновения неисправности. Важно сделать это таким образом, чтобы количество образцов, соответствующих классу ИСП («исправно»), было таким же, как и в других классах, что необходимо для получения сбалансированного набора данных. В общей сложности должно получиться 26400 образцов, из которых 21120 будут использоваться для обучения, а 5280 для тестирования нейронной сети. Обнаружение возникновения неисправности с использованием перехода от класса «исправно» к одному из других классов может оказаться сложным из-за возникновения множества таких переходов в какой-то момент времени.

В работе [2] был предложен фильтр, устраняющий эту неопределенность. Однако он может вызвать значительную задержку в обнаружении неисправности, даже несмотря на относительно высокую частоту дискретизации. Поэтому участки с меньшим количеством данных после возникновения неисправности (<20%) не используются для обучения этой сети. Тем не менее, сложность в определении точного времени возникновения неисправности сохраняется, а это является важным для данной СИИ. В связи с этим предлагается использовать нейронную сеть Conv1D-LSTM с двумя выходами, способную не только классифицировать неисправность, но и определять время ее возникновения. Это можно использовать для улучшения работы второй сети, определяющей местоположение неисправности, так, например, и для управления силовым предохранителем.

Сеть состоит из трех одномерных сверточных слоев с размером ядра 41 и 8, 16, 32 фильтрами в каждом слое с функцией активации ReLU. Слой пулинга с размером ядра, равным 4, используется после первого сверточного слоя, в отличие от [8], и, кроме того, для сверточных слоев используется каузальное дополнение по краям, не разрушающее временной порядок данных [9]. Полученный результат затем дублируется, и каждая копия подается на свой LSTM-слой с 64 ячейками без преобразования в вектор, в отличие от [8], так как LSTM-слой способен обрабатывать временные ряды любой размерности. Полносвязные слои следуют за обоими LSTM-слоями. Первый слой с функцией активации softmax состоит из 11 нейронов, на выходе которых получаются вероятности принадлежности входного образца к одному из классов. Второй слой содержит 1 нейрон с линейной функцией активации, на выходе которого получается номер отсчета, соответствующий началу возникновения неисправности в текущем входном образце. Для образцов, не содержащих неисправности, этот выход должен быть равен 0. Для обучения сети можно использовать оптимизатор ADAM [10] со скоростью обучения $l_r = 10^{-5}$. Для выходного слоя в качестве функции потерь lf_1 используется мультикатегориальная кроссэнтропия:

$$lf_1 = -\sum_{i=1}^n \sum_{j=0}^{10} y_{ij} \ln \widehat{y}_{ij} \quad (10)$$

где y_{ij} – вероятность i -го обучающего образца, соответствующего j -му классу, \widehat{y}_{ij} – вероятность того, что i -й обучающий образец на выходе сети будет соответствовать j -му классу и n – общее количество обучающих образцов. Для выходного слоя другой сети необходимо использовать среднеквадратическую ошибку lf_2 :

$$lf_2 = \frac{1}{n} \sum_{i=1}^n (\widehat{y}_i - y_i)^2, \quad (11)$$

где y_i и \widehat{y}_i – фактический и определяемый сетью номер отсчета, соответствующий началу возникновения неисправности.

Архитектура глубокой нейронной сети для определения местоположения неисправности. Архитектура сети для определения местоположения неисправности в кабельной линии показана на рис. 4, на вход сети поступают 6-мерные данные для значений

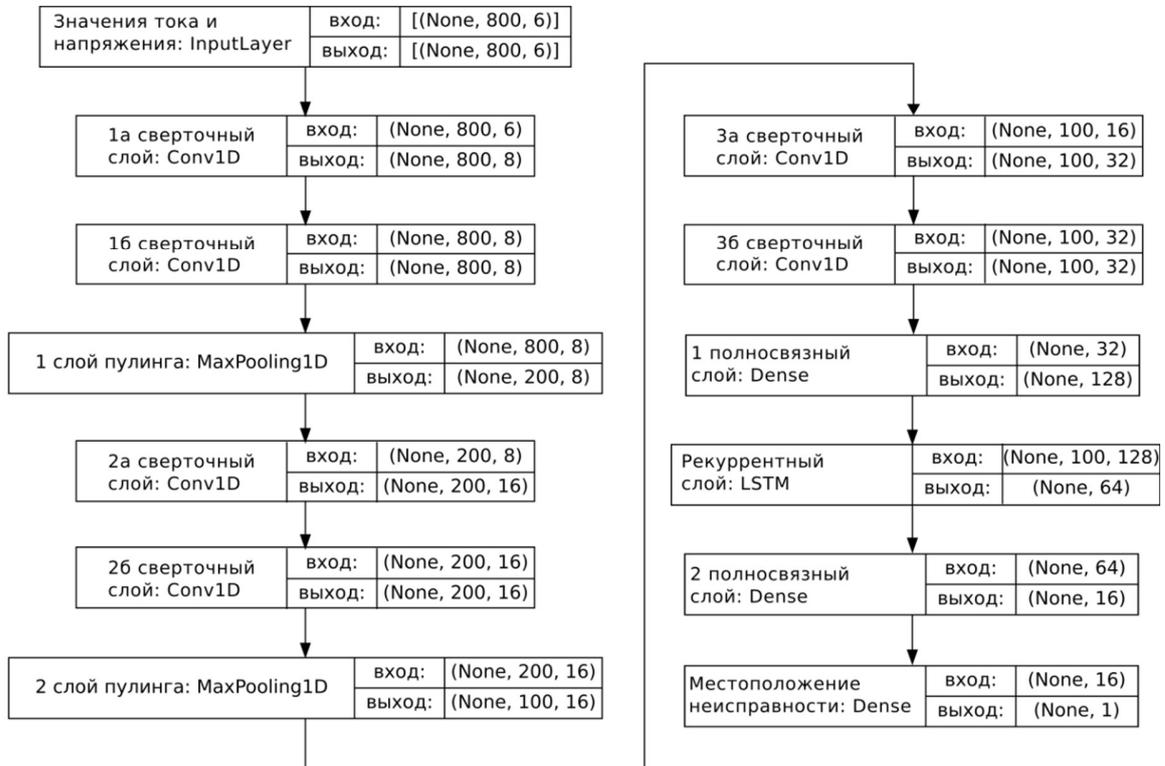


Рисунок 4 – Архитектура глубокой нейронной сети для определения местоположения неисправности

тока и напряжения по 3 фазам. Так как эта задача является более сложной, по сравнению с предыдущей, для ее решения необходимо использовать более глубокую нейронную сеть. Поэтому можно поступить так, как описано в работе [8], взяв 2 подряд идущих сверточных слоя, за которыми следует слой пулинга, и повторить этот шаблон 3 раза. Далее следует полносвязный слой для сжатия размерности данных, а потом LSTM-слой и еще один полносвязный слой перед выходным слоем, состоящим из одного нейрона с линейной функцией активации для определения местоположения неисправности. Вход этой сети также является двумерным с формой 800x6 отсчетов из образцов, обрезанных таким образом, чтобы присутствовало не менее 20% данных после возникновения неисправности, так чтобы данные, не содержащие информации о неисправности, гарантированно не использовались для обучения этой сети, так как эта сеть задействуется только в случае возникновения неисправности. Из каждой выборки модельных данных нужно взять по 5 фрагментов, что в сумме дает 60000 образцов, 48 000 для обучения и 12000 для тестирования нейронной сети соответственно.

Таким образом, эта сеть состоит из 3 стеков сверточных слоев, по 2 слоя в каждом, аналогичным тем, что использовались в первой сети. После каждого слоя, кроме первого, следует слой пулинга с размером ядра, равным 2, после первого слоя используется пул-

линг с размером ядра 4, для того чтобы сократить количество входных данных и ускорить работу нейронной сети.

Затем следует полносвязный слой со 128 нейронами и слой LSTM из 64 ячеек. И еще один полносвязный слой с 16 нейронами идет перед выходным слоем с одним нейроном и линейной функцией активации. Для более стабильного обучения глубокой сети можно использовать оптимизатор ADAM с $l_r = 10^{-5}$ и уменьшающейся в 2 раза скоростью обучения, если обнаруживается, что функция потерь изменяется незначительно (к примеру, меньше чем на 5% за 5 эпох обучения). В качестве функции потерь используется средняя квадратическая ошибка, рассчитываемая по формуле (11), где y_i и \widehat{y}_i – фактическое и определяемое сетью местоположение неисправности в i -м обучающем образце.

Результаты работы обученной сети для определения типа неисправности на тестовых модельных данных показаны в табл. 2. Общая точность на модельных данных составила 99.71%, по каждому классу минимальная и максимальная точность составляет 99.31% и 100% соответственно. Таким образом, сеть способна обнаружить и классифицировать неисправность с достаточно высокой точностью, причем небольшое количество ошибок связано в основном с неисправностями типов ФЗ и ФФЗ из-за схожести их сигналов.

Таблица 2 – Матрица ошибок и точность определения каждого класса неисправностей

		Действительный тип неисправности										
		АЗ	БЗ	ВЗ	АБЗ	БВЗ	АВЗ	АБ	БВ	АВ	АБВЗ	ИСП
Определенный сетью тип неисправности	АЗ (100%)	581	0	0	0	0	0	0	0	0	0	0
	БЗ (100%)	0	603	0	0	0	0	0	0	0	0	0
	ВЗ (99.84%)	0	0	616	0	1	0	0	0	0	0	0
	АБЗ (99.33%)	1	0	0	591	0	0	3	0	0	0	0
	БВЗ (99.51%)	0	0	0	0	605	0	0	3	0	0	0
	АВЗ (99.31)	0	0	0	0	0	578	0	0	4	0	0
	АБ (99.65%)	0	0	0	2	0	0	575	0	0	0	0
	БВ (99.52%)	0	0	0	0	3	0	0	628	0	0	0
	АВ (99.82%)	0	0	0	0	0	1	0	0	564	0	0
	АБВЗ (99.84%)	0	0	0	0	0	0	0	0	1	615	0
ИСП (100%)	0	0	0	0	0	0	0	0	0	0	619	

Авторы работы [11] провели исследование различных способов обработки данных, и их влияние на точность классификации. Ими было обнаружено, что использование сигналов напряжения и тока повышает точность по сравнению с использованием только сигналов тока или напряжения. Однако они показывают, что это улучшение незначительно, так как на низких частотах значения напряжения не содержат достаточно информации относительно класс неисправности. Поэтому в предложенной СИИ используется частота дискретизации 8 кГц, что достаточно для того, чтобы получить большую точность классификации, по сравнению с результатами, полученными в работе [8].

Средняя абсолютная ошибка при определении времени возникновения неисправности время равна 0.35 мс. С учетом наличия аддитивного шума и относительно низкой ча-

стоты дискретизации 8 кГц (0.125 мс) такую ошибку можно считать вполне удовлетворительной.

На рис. 5 представлен график абсолютной погрешности определения времени возникновения неисправности, в зависимости от образцов входных данных. Образцы отличаются начальными отсчетами внутри окна, соответствующими началу возникновения неисправности. Например, первая слева точка на рис. 5 соответствует среднему абсолютному значению ошибки, в которых неисправность возникает в пределах первых 40 точек окна (или в течение первых 5 мс) данных.

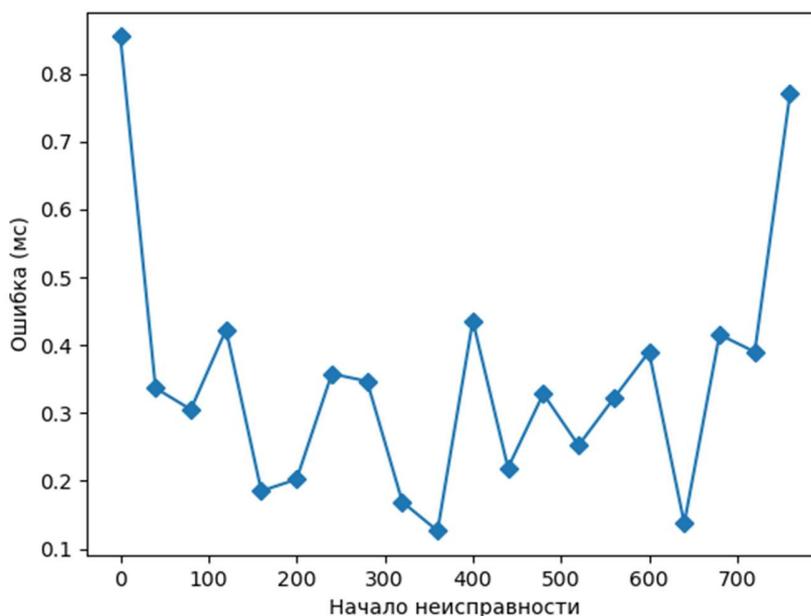


Рисунок 5 – Зависимость ошибки определения времени возникновения неисправности от ее положения в образце данных

Можно заметить, что средняя абсолютная ошибка для образцов, в которых неисправность, возникает на краях, относительно больше. Это можно объяснить тем, что в сеть не имеет достаточно данных для обнаружения неисправности в таком небольшом интервале времени.

Результаты работы сети для определения местоположения неисправности показаны на рис. 6. На этом графике показаны средние абсолютные ошибки определения местоположения неисправности в зависимости от расстояния до ее локализации. Например, первая точка соответствует среднему значению абсолютной ошибки местоположения неисправности для образцов исходных данных, где неисправность возникает на первом километре кабеля. В целом средняя абсолютная ошибка при определении местоположения неисправности составляет 0.11% (или 21.4 м), что немного меньше, чем получено в работе [8]. Улучшение можно объяснить увеличенной в два раза частотой дискретизации исходных данных. Таким образом, СИИ позволяет определить местонахождение неисправности с достаточно высокой точностью, что может значительно облегчить ручной поиск точного места расположения неисправности.

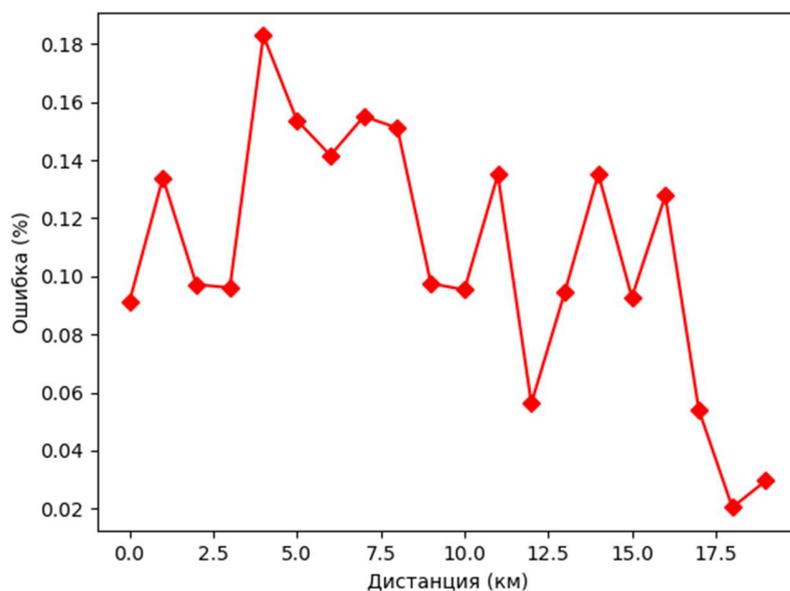


Рисунок 6 – Зависимость ошибки определения местоположения неисправности в зависимости от расстояния до нее

Заключение. В настоящей работе предложена СИИ для онлайн-мониторинга неисправностей подземных кабельных линий, использующая специализированное программное обеспечение для получения большого набора данных для обучения глубоких нейронных сетей, и изложена процедура подготовки данных, необходимых для обучения. Кроме того, предложены архитектуры глубоких нейронных сетей на основе Conv1D и LSTM-слоев. Был собран большой набор данных по описанному способу, и использован для обучения глубоких нейронных сетей. Показаны результаты работы предложенной СИИ на модельных данных. В дальнейшем планируется проверить возможность использования предложенной СИИ для решения поставленной практической задачи в реальных условиях.

Литература

1. Patel B, Bera P. Detection of power swing and fault during power swing using Lissajous figure // IEEE trans power deliv. – 2018. – N 33(6). – P. 3019–3027
2. K. R. K, Dash PK, A new real-time fast discrete S-transform for cross-differential protection of shunt-compensated power systems // IEEE Trans Power Deliv. – 2013. – N 28(1). – P. 402–410
3. Mohd Amiruddin AAA, Zabiri H, Taqvi SAA, Tufa LD Neural network applications in fault diagnosis and detection: an overview of implementations in engineering-related systems // Neural Comput Appl. –2020. – N 32(2). – P. 447–472
4. Верзунов С.Н. Применение глубоких нейронных сетей для краткосрочного прогноза дальности видимости // Проблемы автоматики и управления. – 2019. – № 1 (36). – С. 118–130.
5. Zhang F, Liu Q, Liu Y, Tong N, Chen S, Zhang C. Novel fault location method for power systems based on attention mechanism and double structure GRU neural network // IEEE Access. – 2020. – N 8. – P. 75237–75248

6. Qiao M, Yan S, Tang X, Xu C. Deep convolutional and LSTM recurrent neural networks for rolling bearing fault diagnosis under strong noises and variable loads // IEEE Access. – 2020. – N 8. – P. 66257–66269
7. Антонио Джулли, Суджит Пал. Библиотека Keras – инструмент глубокого обучения. – М.: ДМК Пресс, 2018. – 294 с.
8. Swaminathan, R., Mishra, S., Routray, A. et al. A CNN-LSTM-based fault classifier and locator for underground cables // Neural Comput & Applic. 2021. <https://doi.org/10.1007/s00521-021-06153-w>
9. <https://arxiv.org/abs/1609.03499v2> (дата обращения: 07.06.21)
10. <https://arxiv.org/abs/1412.6980v9> (дата обращения: 07.06.21)
11. Chen K, Hu J, He J Detection and classification of transmission line faults based on unsupervised feature learning and convolutional sparse autoencoder // IEEE Trans Smart Grid. - 2016. - N9(3). – P. 1748–1758