

<https://doi.org/10.21122/1029-7448-2021-64-6-479-491>

УДК 621.316.925

Разработка в MATLAB-Simulink искусственной нейронной сети для восстановления искаженной формы вторичного тока

Часть 1

Ю. В. Румянцев¹⁾, Ф. А. Романюк¹⁾

¹⁾Белорусский национальный технический университет (Минск, Республика Беларусь)

© Белорусский национальный технический университет, 2021
Belarusian National Technical University, 2021

Реферат. В последнее время наблюдается повышенный интерес к применению искусственных нейронных сетей в различных отраслях электроэнергетики, в том числе в релейной защите. Существующие микропроцессорные устройства релейной защиты используют традиционную цифровую обработку контролируемых сигналов, сводящуюся к умножению значений последовательных выборок контролируемых сигналов тока и напряжения на заранее определенные коэффициенты с целью установления их действующих величин. При этом вычисляемые действующие значения часто не отражают реальных процессов, происходящих в защищаемом электрооборудовании ввиду, например, насыщения трансформатора тока апериодической составляющей тока повреждения. При насыщении трансформатора тока его вторичный ток имеет характерную непериодическую искаженную форму, существенно отличающуюся от его первичной (истинной) формы, что ведет к занижению вычисляемого действующего значения вторичного тока по сравнению с его истинной действующей величиной. Указанное приводит к затягиванию времени срабатывания или вовсе к отказу функционирования устройств релейной защиты электрооборудования. Использование искусственной нейронной сети совместно с традиционной цифровой обработкой сигналов обеспечивает иной подход к функционированию как измерительной, так и логической частей микропроцессорного устройства релейной защиты, что позволяет значительно повысить быстродействие и надежность функционирования таких устройств релейной защиты по сравнению с их традиционной реализацией. Возможное приложение искусственной нейронной сети для целей релейной защиты заключается в определении факта возникновения повреждения и его вида, восстановлении формы искаженного сигнала вторичного тока трансформатора тока вследствие его насыщения до истинного значения, установлении искаженных и неискаженных участков сигнала вторичного тока трансформатора тока при его насыщении, выявлении аномальных режимов работы силового оборудования, сопровождающихся искажением контролируемых устройствами релейной защиты величин, таких как бросок тока намагничивания силового трансформатора. В статье детально рассмотрены этапы практической реализации искусственной нейронной сети в среде имитационного

Адрес для переписки

Романюк Федор Алексеевич
Белорусский национальный технический университет
просп. Независимости, 65/2,
220013, г. Минск, Республика Беларусь
Тел.: +375 17 331-00-51
faromanuk@bntu.by

Address for correspondence

Romaniuk Fiodar A.
Belarusian National Technical University
65/2, Nezavisimosty Ave.,
220013, Minsk, Republic of Belarus
Tel.: +375 17 331-00-51
faromanuk@bntu.by

моделирования MATLAB-Simulink на примере ее использования для восстановления искаженной вследствие насыщения формы вторичного тока трансформатора тока.

Ключевые слова: искусственная нейронная сеть, релейная защита, трансформатор тока, насыщение, MATLAB-Simulink

Для цитирования: Румянцев, Ю. В. Разработка в MATLAB-Simulink искусственной нейронной сети для восстановления искаженной формы вторичного тока. Часть 1 / Ю. В. Румянцев, Ф. А. Романюк // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2021. Т. 64, № 6. С. 479–491. <https://doi.org/10.21122/1029-7448-2021-64-6-479-491>

An Artificial Neural Network Developed in MATLAB-Simulink for Reconstruction a Distorted Secondary Current Waveform

Part 1

Yu. V. Rumiantsev¹⁾, F. A. Romaniuk¹⁾

¹⁾Belarusian National Technical University (Minsk, Republic of Belarus)

Abstract. Recently, there has been an increased interest in the use of artificial neural networks in various branches of the electric power industry including relay protection. Artificial neural networks are one of the fastest growing areas in artificial intelligence technology. Recently, there has been an increased interest in the use of artificial neural networks in the electric power engineering, including relay protection. Existing microprocessor-based relay protection devices use a traditional digital signal processing of the monitored signals which is reduced to a multiplying the values of successive samples of the monitored current and voltage signals by predetermined coefficients in order to calculate their RMS values. In this case, the calculated RMS values often do not reflect the real processes occurring in the protected electrical equipment due to, for example, current transformer saturation because of the DC component presence in the fault current. When the current transformer is saturated, its secondary current waveform has a characteristic non-periodic distorted form, which is significantly differs from its primary (true) waveform, which causes underestimation of the calculated RMS value of the secondary current compared to its true value. In its turn, this causes to a trip time delay or even to a relay protection devices operation failure. The use of artificial neural networks in conjunction with a traditional digital signal processing provides a different approach to the functioning of both the measuring and logical parts of the microprocessor-based relay protection devices, which significantly increases the speed and reliability of such relay protection devices in comparison with their traditional implementation. A possible application of the artificial neural networks for the relay protection purposes is the fault occurrence detection and its type identification, current transformer secondary current waveform distortion restoration due to its saturation up to its true value, detection the distorted and undistorted sections of the current transformer secondary current waveform during its saturation, primary power equipment abnormal operating modes detection, for example, power transformer magnetizing current inrush. The article describes in detail the stages of the practical implementation of the artificial neural networks in the MATLAB-Simulink environment by the example of its use to restore the distorted current transformer secondary current waveform due to saturation.

Keywords: artificial neural network, relay protection, current transformer, saturation, MATLAB-Simulink

For citation: Rumiantsev Yu. V., Romaniuk F. A. (2021) An Artificial Neural Network Developed in MATLAB-Simulink for Reconstruction a Distorted Secondary Current Waveform. Part 1. *Energetika. Proc. CIS Higher Educ. Inst. and Power Eng. Assoc.* 64 (6), 479–491. <https://doi.org/10.21122/1029-7448-2021-64-6-479-491> (in Russian)

Введение

Правильность функционирования релейной защиты определяется, в общем, фактором случайности и неопределенности [1]. Невозможно заранее предугадать, какое появится повреждение и какие токи при этом будут его сопровождать, в какой момент времени возникнет повреждение, будет ли происходить насыщение трансформатора тока (ТТ) и с какой степенью.

К насыщению ТТ и, как следствие, неправильному его функционированию приводят следующие факторы: наличие экспоненциально затухающей апериодической составляющей в токе повреждения, превышение установленного током повреждения допустимого значения, наличие остаточной намагниченности стали магнитопровода ТТ и превышение допустимого сопротивления нагрузки, подключенной ко вторичным цепям.

При насыщении ТТ, например при наличии экспоненциально затухающей апериодической составляющей в токе повреждения, его вторичный ток имеет характерную непериодическую искаженную форму (рис. 1), существенно отличающуюся от его первичной (идеальной, истинной) формы, т. е. от такой формы, ток которой протекал бы во вторичных цепях ТТ и подводился к устройствам релейной защиты (РЗ) при отсутствии насыщения. В результате происходит занижение вычисляемого РЗ действующего значения протекающего вторичного тока по сравнению с его истинным действующим значением, что ведет к значительному затягиванию времени срабатывания РЗ или вовсе к отказу ее функционирования, так как устройства токовой РЗ срабатывают при превышении протекающим в месте их установки током заранее установленного значения – уставки срабатывания [2, 3]. Как видно из рис. 1, время срабатывания РЗ t_2 при наличии насыщения ТТ в пять раз превышает время срабатывания РЗ t_1 при его отсутствии. Полученная задержка ликвидации повреждения может повлечь за собой термические повреждения электрооборудования и нарушение селективности устройств РЗ рассматриваемой части энергосистемы, т. е. можно говорить, что в представленном случае отсутствовало правильное функционирование устройства РЗ.

В некоторых современных устройствах РЗ используются специализированные алгоритмы, позволяющие защите правильно функционировать при определенных степенях насыщения ТТ. Данные алгоритмы построены на традиционной цифровой обработке сигналов и в основном производят восстановление искаженных участков сигналов вторичного тока, используя специальные информационные параметры, рассчитанные на участках сигналов вторичного тока, предшествующих насыщению, – так называемых участках точной трансформации [4–6].

Такие алгоритмы сложны, требуют большого количества входной информации, имеют множество ограничений и не всегда эффективны. Искусственная нейронная сеть (ИНС) свободна от указанных недостатков и дает возможность обеспечить правильное функционирование РЗ в условиях

насыщения ТТ (применительно к рис. 1: использование ИНС совместно с РЗ позволяет максимально приблизить кривую 3 к кривой 4, тем самым обеспечив приблизительное равенство времен $t_2 \approx t_1$).




Рис. 1. Форма вторичного тока трансформатора тока при его насыщении: 1, 2 – реальный и идеальный вторичные токи; 3, 4 – действующее значение реального и идеального вторичных токов; 5 – уставка срабатывания токовой релейной защиты

Fig. 1. Current transformer secondary current waveform during saturation: 1, 2 – real and ideal secondary currents; 3, 4 – real and ideal secondary currents RMS value; 5 – relay protection trip threshold

Архитектура искусственной нейронной сети

Своим появлением ИНС обязана развитию знаний о принципах функционирования человеческого мозга, а именно нейрона, обладающего возможностью получения, обработки и дальнейшей передачи электрохимических сигналов по нервным путям [7]. Искусственный нейрон (рис. 2) в ИНС представляет собой единицу обработки информации и является упрощенным прототипом биологического нейрона, предназначенного для выполнения аналогичных функций в мозге.




Рис. 2. Модель искусственного нейрона

Fig. 2. Artificial neuron model

Искусственный нейрон можно представить как вычислительный узел, на входы которого поступают некоторые входные значения (x_1, x_2, \dots, x_n). Каждый вход нейрона имеет свой собственный весовой коэффициент

циент (w_1, w_2, \dots, w_n) , т. е. перед поступлением в нейрон каждое входное значение умножается на соответствующий весовой коэффициент (вес) и только после этого поступает непосредственно в нейрон, где суммируется с остальными взвешенными значениями, поступившими на другие входы, и с величиной смещения b , предназначенного для более точной подстройки значения на выходе нейрона. Таким образом, в нейроне формируется некоторое промежуточное выходное значение $S = (x_1 w_1 + x_2 w_2 + \dots + x_n w_n) + b$, поступающее на вход активационной функции F , на выходе которой и формируется окончательное выходное значение нейрона y . Назначением указанной функции является ограничение амплитуды значения S до уровня выходной величины y .

Существует большое разнообразие активационных функций F . Рассмотрим одну из наиболее распространенных нелинейных функций – гиперболический тангенс, которая в зависимости от поступающего на ее вход значения S возвращает на свой выход величину y в диапазоне (-1) – 1 . Таким образом, выходное значение нейрона зависит от многих переменных

$$y = f([x_1, x_2, \dots, x_n], [w_1, w_2, \dots, w_n], b, F).$$

Для построения ИНС образующие ее нейроны должны быть определенным образом объединены в так называемые слои, где каждый нейрон соединен с каждым из нейронов предыдущего и последующего слоев, причем связь между нейронами одного слоя отсутствует. В общем случае ИНС состоит из входного слоя, одного или нескольких скрытых слоев и выходного слоя (рис. 3). В качестве функции активации для нейронов выходного слоя часто используют линейные функции, которые возвращают на свой выход поступающее на вход значение. Это нужно при выполнении задач аппроксимации, чтобы не ограничивать выходные величины ИНС каким-либо диапазоном. При отсутствии такой необходимости (например, при решении задач классификации) может использоваться нелинейная функция.




Рис. 3. Одна из возможных конфигураций многослойной искусственной нейронной сети

Fig. 3. One of the possible configurations of a multilayer artificial neural network

Следует отметить, что вычисления производятся только в скрытых и выходном слоях, входной слой не содержит нейронов и предназначен исключительно для ввода в ИНС входных значений. Веса w и смещения b на рис. 3 не показаны.

Для получения высокой производительности количество скрытых слоев может быть более одного, тогда сети называются многослойными ИНС. При этом число как самих слоев, так и нейронов в них может различаться и подбирается опытным путем. В данных сетях выходы предыдущего слоя являются входами последующего. Однако для аппроксимации нелинейных зависимостей между входными и выходными значениями достаточно иметь ИНС с одним скрытым слоем и приемлемым числом нейронов в нем [8].

После того как выбрана конфигурация ИНС, ее необходимо обучить. Под процессом обучения понимается совокупность действий, приводящих к тому, что ИНС на своих выходах возвращает желаемые (или близкие к ним) значения при заданных входных. Для обучения требуется заранее подготовленный набор обучающих данных, состоящий из пар входных и соответствующих им выходных значений:

$$\left[\left(x_1^1 \dots x_1^q, y_1^1 \dots y_1^i \right), \left(x_2^1 \dots x_2^q, y_2^1 \dots y_2^i \right) \dots \left(x_n^1 \dots x_n^q, y_n^1 \dots y_n^i \right) \right],$$

где $x_n^1 \dots x_n^q$ – входные значения обучающей пары; $y_n^1 \dots y_n^i$ – соответствующие $x_n^1 \dots x_n^q$ выходные (желаемые) величины обучающей пары.

При этом количество входных значений q обучающей пары может не равняться числу ее выходных величин i , но для каждой обучающей пары набора указанное соотношение должно быть одинаковым. Количество обучающих пар n должно по возможности описывать практически все режимы функционирования заменяемого ИНС реального объекта.

Упрощенно обучение сводится к последовательной многократной подаче на входы ИНС значений $x_n^1 \dots x_n^q$ каждой обучающей пары, сравнению возвращаемых ИНС величин $y_n^{1*} \dots y_n^{i*}$ со значениями $y_n^1 \dots y_n^i$ и вычислению ошибки (разницы между желаемой и полученной величинами). Далее при известной величине ошибки по специальному алгоритму обратного распространения происходит корректировка значений весовых коэффициентов w и смещений b с целью минимизации получаемой ошибки обучения. Из вышеизложенного следует, что обучение ИНС – это процесс поиска глобального минимума многомерной функции ошибки, переменными для которой являются всевозможные сочетания весов и смещений.

При успешном завершении обучения можно утверждать, что ИНС произвела аппроксимацию нелинейного отображения между входными и выходными обучающими данными и приобрела способность возвращать желаемые значения на свои выходы при подаче на ее входы величин, равных или близких к входным значениям обучающего набора.

Процесс обучения прекращается при достижении усредненной для всех пар набора обучающих данных ошибкой некоторого малого значения, или при превышении заданного числа эпох алгоритма обучения (числа проговов всех пар набора обучающих данных через ИНС), или в случае превышения заданного времени обучения. Однако ни один из перечисленных критериев остановки обучения не гарантирует успешность данного процесса, так как при аппроксимации нелинейных зависимостей ошибка ИНС не может равняться нулю, а точное приемлемое ее значение заранее знать невозможно. И даже минимизация ошибки не свидетельствует о качестве обучения, поскольку мощность ИНС бывает в принципе недостаточной или избыточной для аппроксимации требуемой зависимости либо же найденный минимум ошибки оказывается локальным, а не глобальным [9].

Наиболее серьезная проблема при обучении ИНС – ее переобучение, т. е. потеря главного свойства – обобщения, что проявляется в неспособности ИНС правильно функционировать при подаче на ее входы значений, которые отсутствовали в наборе обучающих данных, но близки к ним. Способность ИНС к обобщению по сути является интерполированием, возможностью предсказывать неизвестные значения функции по их известным смежным величинам. Стоит отметить, что ИНС не обладает свойствами экстраполяции (т. е. способностью предсказывать значения вне диапазона обучающих данных), поэтому набор обучающих данных должен охватывать весь возможный диапазон их изменения [10].

Переобучение возникает при чрезмерном по отношению к сложности решаемой задачи количестве нейронов в ИНС. Тогда вычислительная мощность (гибкость) ИНС, определяемая числом свободных параметров – весов w и смещений b , оказывается намного больше, чем необходимо для выполнения аппроксимации нелинейного отображения между входными и выходными обучающими данными.

Существуют два пути решения указанной выше проблемы: постепенное упрощение конфигурации ИНС до нахождения достаточного количества свободных параметров, обеспечивающих оптимальную с точки зрения решаемой задачи конфигурацию ИНС, либо использование специальных искусственных методов ограничения мощности ИНС без изменения ее конфигурации.

Чем большие значения присваиваются свободным параметрам ИНС в процессе обучения, тем выше ее вычислительная мощность. Поэтому если не позволить им приобрести большие значения, это ограничит вычислительную мощность ИНС с неоптимальной по отношению к решаемой задаче конфигурацией, и такая ИНС с искусственно ограниченными значениями свободных параметров по своей мощности сравняется с ИНС с оптимальной конфигурацией.

Рассмотрим один из подобных методов, так называемую раннюю остановку, основанный на остановке обучения ИНС до момента приобретения

ее весами и смещениями больших значений. В этом случае некоторая часть набора обучающих данных резервируется в качестве проверочного набора и непосредственно не участвует в процессе обучения. Периодически обучение прерывается, и проверочный набор подается на входы ИНС для оценки получаемой ошибки. Если ошибка с каждым разом применения проверочного набора уменьшается, это свидетельствует о том, что переобучение ИНС отсутствует и процесс обучения продолжается. Так происходит до тех пор, пока ошибка на наборе обучающих данных не уменьшится до некоторого малого значения или будет достигнуто максимальное число эпох обучения при условии одновременного монотонного уменьшения ошибки на проверочном наборе.

В случае если обе ошибки в процессе обучения не достигли достаточного малого значения за максимальное число итераций, это может указывать на то, что ИНС не обладает необходимой мощностью для решения поставленной задачи и ее конфигурацию следует изменить в сторону увеличения количества нейронов.

Если получаемая ошибка на проверочном наборе начинает монотонно увеличиваться заданное количество эпох подряд, это свидетельствует о том, что ИНС переобучается, т. е. приобретает избыточную для конкретного набора обучающих данных вычислительную мощность за счет увеличения значений свободных параметров. В данном случае обучение останавливается и алгоритм обучения возвращает ИНС весовые коэффициенты w и смещения b , при которых ошибка на проверочном наборе была минимальной.

Поскольку проверочный набор в процессе обучения используется многократно, он может влиять на процесс обучения ИНС, становясь как бы частью обучающего набора, что, в свою очередь, может приводить к получению недостоверных результатов. В связи с этим из набора обучающих данных резервируется еще одна часть – тестовый набор, который применяется один раз уже после окончания обучения ИНС для подтверждения адекватности показателей качества ее функционирования, полученных на обучающем и проверочном наборах [11].

Еще одним известным методом ограничения мощности ИНС без изменения ее конфигурации является регуляризация. Процесс обучения контролируется специальным алгоритмом, минимизирующим не только ошибку ИНС, но и квадратичную сумму значений ее весов и смещений, что не позволяет им увеличиваться до больших значений. В этом случае не требуется формирование проверочного набора данных, поэтому большее их количество может использоваться для обучающего набора.

Для обеспечения эффективности и скорости процесса обучения ИНС входные и соответствующие им выходные значения обучающих пар набора обучающих данных должны быть соответствующим образом предварительно обработаны. Например, основным требованием, предъявляемым к входным данным ИНС, является их нормализация к интервалу $(-1)-1$ при наличии в наборе обучающих данных отрицательных значений или к интервалу $(0)-1$ при наличии только положительных значений. Поскольку

эта операция связана с особенностями функционирования алгоритма обучения, к выходным значениям ИНС должна применяться обратная операция, восстанавливающая реальный масштаб набора обучающих данных.

Приложение искусственной нейронной сети для целей релейной защиты

Одно из наиболее перспективных приложений ИНС для РЗ – восстановление искаженной формы сигнала вторичного тока ТТ вследствие насыщения его магнитопровода до истинной формы [12–19]. Если положить, что вторичный ток ТТ является функцией его первичного тока, то цель обучения ИНС заключается в аппроксимации нелинейной зависимости между вторичными и соответствующими им значениями приведенного первичного тока для нахождения инверсной функции, по которой будет осуществляться восстановление формы сигнала вторичного тока ТТ.

Рассмотрим этапы реализации ИНС в системе имитационного моделирования MATLAB-Simulink с использованием пакета расширения Neural Network Toolbox [11] (в последних версиях пакет носит название Deep Learning Toolbox).

Набор обучающих данных должен содержать пары дискретизированных по времени сигналов вторичного тока ТТ (входные значения) и соответствующих им сигналов приведенного первичного тока ТТ (выходные или желаемые значения). Для формирования набора обучающих данных в системе MATLAB-Simulink с использованием блоков пакета расширения SimPowerSystems [20] (Simscape Power Systems в последних версиях) реализована модель части энергосистемы, представленная на рис. 4.

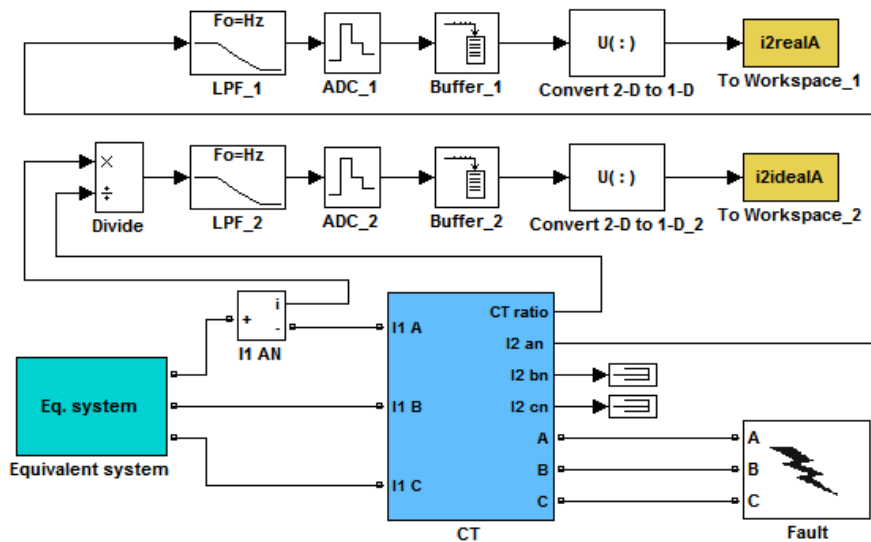


Рис. 4. Формирование набора обучающих данных с использованием модели части энергосистемы, реализованной в MATLAB-Simulink

Fig. 4. Training dataset preparing with the use a MATLAB-Simulink model of an equivalent power system

Рассматриваемая модель включает следующие элементы. Питающая эквивалентная энергосистема (Equivalent system) представляется стандартным блоком модели трехфазного источника напряжения Three-Phase Source. В связи с отсутствием в стандартной библиотеке SimPowerSystems блока ТТ (СТ) он разработан и реализован с использованием стандартных блоков Simulink в соответствии с [21]. Повреждение (Fault) представляется стандартным библиотечным блоком модели трехфазного короткозамыкателя Three-Phase Fault, моделирующим трехфазное устройство, замыкающее фазы между собой, а также на землю. Генерируемые сигналы реального вторичного и приведенного через коэффициент трансформации первичного тока ТТ, подаваемые на вход аналого-цифрового преобразователя (ADC), должны предварительно проходить через фильтр низших частот (LPF). Фильтр низших частот представляется блоком модели 2nd-Order Filter, основной его параметр – значение частоты среза. Аналого-цифровой преобразователь представляется блоком модели Zero-Order Hold, параметром которого является отношение значения длительности периода промышленной частоты к величине числа выборок за данный период. Примем частоту дискретизации, равную 32 отсчетам (выборкам) на период промышленной частоты. Измерение первичного тока (I1 AN) и операция деления представляются блоками Current Measurement и Divide соответственно, данные блоки параметров не имеют. Блоки моделей Buffer, Convert 2-D to 1-D и To Workspace предназначены для формирования из дискретизированных сигналов токов ТТ набора обучающих данных таким образом, что входные (i2realA) и выходное (i2idealA) значения каждой обучающей пары набора являются цифровым отображением скользящего вдоль указанных сигналов тока окна данных.

Формируемый набор обучающих данных должен по возможности отражать все формы вторичного тока ТТ, искаженные вследствие его насыщения. Для их получения необходимо произвести многократный запуск разработанной модели части энергосистемы с изменяющимися в широком диапазоне параметрами блока, моделирующего питающую эквивалентную систему. Общее число запусков модели определяется условием, при выполнении которого осуществляется перебор между собой всех сочетаний значений изменяющихся параметров модели с учетом шага их изменения.

Трансформатор тока принят со следующими параметрами: коэффициент трансформации 600/5 А (т. е. $I_{\text{ном}} = 600$ А), номинальная предельная кратность ($K_{\text{ном}}$) 20, номинальная вторичная нагрузка ($S_{\text{ном}}$) 20 В·А, фактическая вторичная нагрузка ($S_{\text{н}}$) 20 В·А, класс точности 10Р.

Действующее значение тока КЗ $I_{\text{кз}}$ изменяется в диапазоне $(0,5I_{\text{ном}}K_{\text{ном}} - 3I_{\text{ном}}K_{\text{ном}})$ А. Постоянная времени экспоненциально затухающей аperiodической составляющей тока повреждения τ изменяется в диапазоне 0–0,1 с. Угол возникновения повреждения φ изменяется в диапазоне 0–360°.

В связи с изменением во всем возможном диапазоне φ набор обучающих данных формировался с использованием только токов ТТ фазы А.

Момент возникновения повреждения соответствует моменту начала моделирования.

Время симуляции модели составляло два периода промышленной частоты – 0,04 с. Таким образом, после каждого запуска модели формируются (с учетом скользящего окна данных) по 32 пары набора обучающих данных для каждого периода промышленной частоты, т. е. суммарно для двух периодов – 64 пары. Процесс многократного запуска и изменения параметров модели автоматизирован средствами MATLAB.

Результаты выполненных исследований будут представлены во второй части статьи.

ВЫВОДЫ

1. Анализ функциональных возможностей искусственных нейронных сетей подтверждает целесообразность их использования в технике релейной защиты.

2. Одним из наиболее перспективных приложений искусственной нейронной сети для целей релейной защиты является восстановление искаженного сигнала вторичного тока трансформатора тока до истинной формы.

3. Реализованная в среде имитационного моделирования MATLAB-Simulink модель части энергосистемы позволяет формировать набор данных для обучения искусственной нейронной сети восстановлению искаженной формы вторичного тока трансформатора тока вследствие насыщения его магнитопровода.

ЛИТЕРАТУРА

1. Шалин, А. И. Надежность и диагностика релейной защиты энергосистем / А. И. Шалин. Новосибирск: НГТУ, 2002. 383 с.
2. Совершенствование алгоритма формирования ортогональных составляющих входных величин в микропроцессорных защитах / Ф. А. Романюк [и др.] // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2021. Т. 64, № 2. С. 95–108. <https://doi.org/10.21122/1029-7448-2021-64-2-95-108>.
3. Формирование ортогональных составляющих входных токов в микропроцессорных защитах электроустановок / Ф. А. Романюк [и др.] // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2021. Т. 64, № 3. С. 191–201. <https://doi.org/10.21122/1029-7448-2021-64-3-191-201>.
4. Pan, J. An Efficient Compensation Algorithm for Current Transformer Saturation Effects / J. Pan, K. Vu, Y. Hu // IEEE Transactions on Power Delivery. 2004. Vol. 19, Iss. 4. P. 1623–1628. <https://doi.org/10.1109/TPWRD.2004.835273>.
5. Villamagna, N. A CT Saturation Detection Algorithm Using Symmetrical Components for Current Differential Protection / N. Villamagna, P. Crossley // IEEE Transactions on Power Delivery. 2006. Vol. 21, Iss. 1. P. 38–45. <https://doi.org/10.1109/TPWRD.2005.848654>.
6. Wiszniewski, A. Correction of Current Transformer Transient Performance / A. Wiszniewski, W. Rebizant, L. Schiel // IEEE Transactions on Power Delivery. 2008. Vol. 23, Iss. 2. P. 624–632. <https://doi.org/10.1109/TPWRD.2008.915832>.

7. Haykin, S. *Neural Networks and Learning Machines* / S. Haykin. 3rd ed. Pearson Education India, 2010. 936 p.
8. Cybenko, G. Approximation by Superpositions of a Sigmoidal Function / G. Cybenko // *Mathematics of Control, Signals and Systems*. 1989. Vol. 2, Iss. 4. P. 303–314. <https://doi.org/10.1007/bf02551274>.
9. *Neural Network Toolbox. User's Guide. Version 4* [Electronic Resource]. The MathWorks, 2002. Mode of access: http://cda.psych.uiuc.edu/matlab_pdf/nnet.pdf.
10. *Neural Network Design* / M. T. Hagan [et al.], 2nd ed. Boston: PWS Publishing, 2014. 1012 p.
11. Медведев, В. С. Нейронные сети. MATLAB 6 / В. С. Медведев, В. Г. Потемкин. М.: Диалог-МИФИ, 2002. 496 с.
12. Rebizant, W. *Digital Signal Processing in Power System Protection and Control* / W. Rebizant, J. Szafran, A. Wiszniewski. London: Springer, 2011. 316 p.
13. Correction of Current Transformer Distorted Secondary Currents Due to Saturation Using Artificial Neural Networks / D. C. Yu [et al.] // *IEEE Transactions on Power Delivery*. 2011. Vol. 16, Iss. 2. P. 189–194. <https://doi.org/10.1109/61.915481>.
14. Khorashadi-Zadeh, H. Correction of Saturated Current Transformers Secondary Current Using ANNs / H. Khorashadi-Zadeh, M. Sanaye-Pasand // *IEEE Transactions on Power Delivery*. 2005. Vol. 21, Iss. 1. P. 73–79. <https://doi.org/10.1109/TPWRD.2005.858799>.
15. Application of Neural Networks in Numerical Busbar Protection Systems (NBPS) / K. Feser [et al.] // *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*. 1991. P. 117–121. <https://doi.org/10.1109/ANN.1991.213508>.
16. Lukowicz, M. Artificial Neural Network Based Dynamic Compensation of Current Transformer Errors / M. Lukowicz, E. Rosolowski // *Proceedings of the 8th International Symposium on Short-Circuit Currents in Power Systems*. 2000. P. 19–24.
17. Haghjoo, F. Compensation of CT Distorted Secondary Current Waveform in Online Conditions / F. Haghjoo, M. H. Pak // *IEEE Transactions on Power Delivery*. 2015. Vol. 31, Iss. 2. P. 711–720. <https://doi.org/10.1109/TPWRD.2015.2448634>.
18. Application of ANN Methods for Instrument Transformer Correction in Transmission Line Protection / M. M. Saha [et al.] // *Developments in Power System Protection, 7th International Conference*. 2001. P. 303–306. <https://doi.org/10.1049/cp:20010160>.
19. Cummins, J. C. Simplified Artificial Neural Network Structure with the Current Transformer Saturation Detector Provides a Good Estimate of Primary Currents / J. C. Cummins, D. C. Yu, L. A. Kojovic // *Power Engineering Society Summer Meeting*. 2000. Vol. 3. P. 1373–1378. <https://doi.org/10.1109/pess.2000.868725>.
20. *SimPowerSystems. User's Guide. Version 5* [Electronic Resource]. The MathWorks, 2011. Mode of access: <https://all-guidesbox.com/manual/545991/matlab-simpowersystems-5-operation-user-s-manual-403.html>.
21. Новаш, И. В. Упрощенная модель трехфазной группы трансформаторов тока в системе динамического моделирования / И. В. Новаш, Ю. В. Румянцев // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2015. № 5. С. 23–38.

Поступила 31.08.2021 Подписана в печать 02.11.2021 Опубликована онлайн 30.11.2021

REFERENCES

1. Shalin A. I. (2002) *Reliability and Diagnostics of Relay Protection of Power Systems*. Novosibirsk, NSTU. 383 (in Russian).
2. Romaniuk F. A., Rumiantsev Yu. V., Rumiantsev V. Yu., Novash I. V. (2021) Improvement of Algorithm for Formation of Orthogonal Components of Input Quantities in Microprocessor Protection. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 64 (2), 95–108. <https://doi.org/10.21122/1029-7448-2021-64-2-95-108> (in Russian).
3. Romaniuk F. A., Rumiantsev Yu. V., Rumiantsev V. Yu., Novash I. V. (2021) Formation of Orthogonal Components of Input Currents in Microprocessor Protections of Electrical Equip-

- ment. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 64 (3), 191–201. <https://doi.org/10.21122/1029-7448-2021-64-3-191-201> (in Russian).
4. Pan J., Vu K., Hu Y. (2004) An Efficient Compensation Algorithm for Current Transformer Saturation Effects. *IEEE Transactions on Power Delivery*, 19 (4), 1623–1628. <https://doi.org/10.1109/TPWRD.2004.835273>.
 5. Villamagna N., Crossley P. (2006) A CT Saturation Detection Algorithm Using Symmetrical Components for Current Differential Protection. *IEEE Transactions on Power Delivery*, 21 (1), 38–45. <https://doi.org/10.1109/TPWRD.2005.848654>.
 6. Wiszniewski A., Rebizant W., Schiel L. (2008) Correction of Current Transformer Transient Performance. *IEEE Transactions on Power Delivery*, 23 (2), 624–632. <https://doi.org/10.1109/TPWRD.2008.915832>.
 7. Haykin S. (2010) *Neural Networks and Learning Machines*. 3rd ed. Pearson Education India. 936.
 8. Cybenko G. (1989) Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals and Systems*, 2 (4), 303–314. <https://doi.org/10.1007/bf02551274>.
 9. *Neural Network Toolbox. User's Guide. Version 4*. The MathWorks, 2002. Available at: http://cda.psych.uiuc.edu/matlab_pdf/nnet.pdf.
 10. Hagan M. T., Demuth H. B., Beale M. H., Jes O. D. (2014) *Neural Network Design*. 2nd ed. Boston, PWS Publishing. 1012.
 11. Medvedev V. S., Potemkin V. G. (2002) *Neural Network. MATLAB 6*. Moscow, Dialog-MIFI Publ. 496 (in Russian).
 12. Rebizant W., Szafran J., Wiszniewski A. (2011) *Digital Signal Processing in Power System Protection and Control*. London, Springer Publ. 316.
 13. Yu D. C., Cummins J. C., Wang Z., Yoon H. J., Kojovic L. A. (2011) Correction of Current Transformer Distorted Secondary Currents Due to Saturation Using Artificial Neural Networks. *IEEE Transactions on Power Delivery*, 16 (2), 189–194. <https://doi.org/10.1109/61.915481>.
 14. Khorashadi-Zadeh H., Sanaye-Pasand M. (2005) Correction of Saturated Current Transformers Secondary Current Using ANNs. *IEEE Transactions on Power Delivery*, 21 (1), 73–79. <https://doi.org/10.1109/TPWRD.2005.858799>.
 15. Feser K., Braun U., Engler F., Maier A. (1991) Application of Neural Networks in Numerical Busbar Protection Systems (NBPS). *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*, 117–121. <https://doi.org/10.1109/ANN.1991.213508>.
 16. Lukowicz M., Rosolowski E. (2000) Artificial Neural Network Based Dynamic Compensation of Current Transformer Errors. *Proceedings of the 8th International Symposium on Short-Circuit Currents in Power Systems*, 19–24.
 17. Haghjoo F., Pak M. H. (2015) Compensation of CT Distorted Secondary Current Waveform in Online Conditions. *IEEE Transactions on Power Delivery*, 31 (2), 711–720. <https://doi.org/10.1109/TPWRD.2015.2448634>.
 18. Saha M. M., Izykowski J., Lukowicz M., Rosolowski E. (2001) Application of ANN Methods for Instrument Transformer Correction in Transmission Line Protection. *Developments in Power System Protection, 7th International Conference*, 303–306. <https://doi.org/10.1049/cp:20010160>.
 19. Cummins, J. C., Yu D. C., Kojovic L. A. (2000) Simplified Artificial Neural Network Structure with the Current Transformer Saturation Detector Provides a Good Estimate of Primary Currents. *Power Engineering Society Summer Meeting*, 3, 1373–1378. <https://doi.org/10.1109/pess.2000.868725>.
 20. *SimPowerSystems. User's Guide. Version 5*. The MathWorks, 2011. Available at: <https://allguidesbox.com/manual/545991/matlab-simpowersystems-5-operation-user-s-manual-403.html>.
 21. Novash I. V., Rumiantsev Yu. V. (2015) A Simplified Model of Three-Phase Bank of Current Transformers in the Dynamic Simulation System. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, (5), 23–38 (in Russian).