

<https://doi.org/10.21122/1029-7448-2022-65-1-5-21>

УДК 621.316.925

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

Часть 2

Ю. В. Румянцев¹⁾, Ф. А. Романюк¹⁾

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

© Белорусский национальный технический университет, 2022
Belarusian National Technical University, 2022

Реферат. Искусственные нейронные сети все чаще используются в различных отраслях электроэнергетики, в том числе в релейной защите. Традиционные микропроцессорные устройства релейной защиты функционируют по принципу вычисления действующих значений контролируемых сигналов тока и напряжения и сравнения их с заранее заданными уставками. Однако вычисляемые действующие величины не всегда отражают реальные процессы, происходящие в защищаемом электрооборудовании, ввиду, например, насыщения трансформатора тока. В таком режиме вторичный ток имеет характерную искаженную форму, которая существенно отличается от идеальной (истинной). Это ведет к занижению вычисляемого релейной защитой действующего значения основной гармоники вторичного тока по сравнению с его истинной действующей величиной и приводит к затягиванию времени срабатывания или отказу функционирования устройств релейной защиты. Одно из перспективных приложений искусственной нейронной сети для целей релейной защиты – восстановление истинной формы сигнала вторичного тока трансформатора тока при его насыщении. В статье рассмотрены этапы реализации нейронной сети в среде MATLAB на примере ее обучения восстановлению искаженной формы вторичного тока. Выполнена проверка функционирования разработанных нейронных сетей в MATLAB-Simulink. С использованием пакета расширения SimPowerSystems реализована модель, позволяющая имитировать режим насыщения трансформатора тока, сопровождающийся искажением формы сигнала его вторичного тока, и ее последующее восстановление с помощью искусственных нейронных сетей. Полученные результаты подтвердили способность нейронных сетей практически полностью восстанавливать искаженную форму вторичного тока трансформатора тока. Применение обученных искусственных нейронных сетей в реальных устройствах релейной защиты представляется перспективным, поскольку обеспечивает повышение их быстродействия и надежности функционирования.

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

Для цитирования: Румянцев, Ю. В. Разработка в MATLAB-Simulink искусственной нейронной сети для восстановления искаженной формы вторичного тока. Часть 2 / Ю. В. Румянцев, Ф. А. Романюк // *Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ*. 2022. Т. 65, № 1. С. 5–21. <https://doi.org/10.21122/1029-7448-2022-65-1-5-21>

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

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

Part 2

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. The operation of the traditional microprocessor-based relay protection device is based on calculation the RMS values of the monitored current and voltage signals and its comparison with the predetermined thresholds. However, calculated RMS values often do not reflect the real processes occurring in the electrical equipment under protection due to, for example, current transformer saturation. In this case secondary current has a characteristic distorted waveform, which is significantly differs from its ideal (true) waveform. This causes underestimation of the calculated RMS value of the secondary current compared to its true value; also, it causes a trip time delay or even to a relay protection devices operation failure. In this regard, one of the perspective applications of the artificial neural network for the relay protection purposes is the current transformer distorted secondary current waveform restoration due to its saturation. 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 reconstruct the distorted secondary current waveform of the saturated current transformer. The functioning of the developed neural networks was verified in the MATLAB-Simulink environment; with the use of the SimPowerSystems component library a model was implemented which allow simulating the current transformer saturation, accompanied by the secondary current waveform distortion, and its further restoration using developed artificial neural networks. The obtained results confirmed the ability of the neural networks that had been developed to almost completely restore the distorted secondary current waveform. Thus, it seems promising to use pre-trained artificial neural networks in real relay protection devices, since such use will ensure the speed of real relay protection devices; their operation reliability will also increase.

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

For citation: Rumiantsev Yu. V., Romaniuk F. A. (2022) An Artificial Neural Network Developed in MATLAB-Simulink for Reconstruction a Distorted Secondary Current Waveform. Part 2. *Energetika. Proc. CIS Higher Educ. Inst. and Power Eng. Assoc.* 65 (1), 5–21. <https://doi.org/10.21122/1029-7448-2022-65-1-5-21> (in Russian)

Введение

В первой части статьи [1] рассмотрены архитектура искусственной нейронной сети (ИНС) [2–6] и ее приложения к задачам релейной защиты (РЗ) [7, 8], наиболее перспективным из которых является восстановление искаженной формы вторичного тока трансформатора тока (ТТ) вследствие насыщения его магнитопровода [9–18].

Разработанная ИНС может использоваться в реальном темпе моделирования системы MATLAB-Simulink для получения на ее выходе на каждом шаге дискретизации (принят равным 32 отсчетам на период промышленной частоты) обновленного значения восстановленного вторичного тока ТТ при подаче на ее входы скользящего окна данных реального вторичного тока ТТ. Поэтому количество входов и выходов ИНС должно составлять 32 и 1 соответственно (рис. 1).

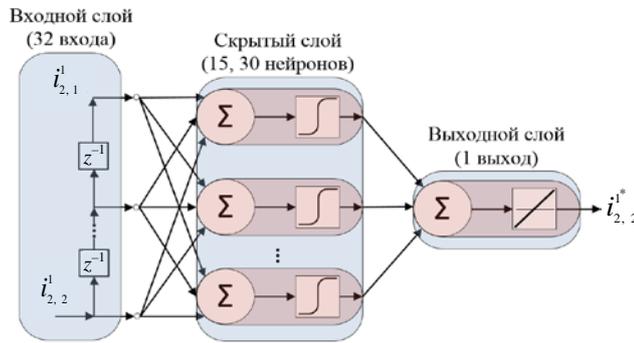


Рис. 1. Конфигурация искусственной нейронной сети для восстановления искаженной формы вторичного тока трансформатора тока

Fig. 1. Artificial neural network topology for reconstruction a current transformer distorted secondary current waveform

В реальном темпе моделирования за каждый период промышленной частоты значения на входах и выходе ИНС обновляются по 32 раза. Поэтому и обучающих пар, получаемых за время симуляции модели (один период промышленной частоты) [1, рис. 4], должно быть 32. Таким образом, в результате каждого запуска модели на время, равное двум периодам промышленной частоты, формировались 64 обучающие пары: первые 32 соответствуют скользящему окну сигнала вторичного тока ТТ в первом периоде, а оставшиеся 32 – во втором периоде. Наличие в наборе обучающих данных форм сигналов двух последовательных периодов промышленной частоты положительно сказывается на получаемой точности восстановления формы искаженного вторичного тока ТТ вследствие его насыщения.

Каждая пара обучающего набора данных должна содержать 32 выборки мгновенного вторичного тока ТТ в качестве входных значений и 1 выборку мгновенного первичного тока ТТ в качестве выходного значения, которое для текущего момента времени через коэффициент трансформации приводится ко вторичному току ТТ (истинное значение). При этом для каждой последующей формируемой пары входные значения задаются 31 старой (содержащейся в предыдущей обучающей паре) выборкой мгновенного вторичного тока ТТ и 1 новой – текущей выборкой, а выходное значение – 1 обновленной выборкой приведенного первичного тока ТТ.

Поскольку момент возникновения повреждения принят совпадающим с началом моделирования (т. е. считается, что в предшествующем режиме ток не протекал), первая формируемая обучающая пара содержит 31 нулевое и 1 текущее входное значение вторичного тока ТТ, вторая – 30 нулевых и 2 текущих и т. д.

С учетом вышеизложенного и принятой частоты дискретизации структура набора обучающих данных имеет вид

$$\left[\left(\left\{ i_{2,1}^1, \dots, i_{2,1}^{32} \right\}, \left\{ i_{2id,1}^{32} \right\} \right), \left(\left\{ i_{2,1}^2, \dots, i_{2,1}^{32}, i_{2,2}^1 \right\}, \left\{ i_{2id,2}^1 \right\} \right), \right. \\ \left. \left(\left\{ i_{2,1}^3, \dots, i_{2,1}^{32}, i_{2,2}^1, i_{2,3}^1 \right\}, \left\{ i_{2id,3}^1 \right\} \right), \dots, \left(\left\{ i_{2,1}^{32}, i_{2,2}^1, i_{2,3}^1, \dots, i_{2,32}^1 \right\}, \left\{ i_{2id,32}^1 \right\} \right) \right],$$

где i_2 – входные вторичные токи; i_{2id} – выходные (желаемые) значения токов обучающих пар.

В пакете Neural Network Toolbox системы MATLAB предусмотрен интуитивно понятный графический интерфейс, требующий от пользователя минимума действий при создании ИНС. Использование интерфейса налагает определенные ограничения на конфигурацию сети и иные специфические настройки ИНС, но позволяет ускорить процесс ее разработки. Кроме того, операции предварительной и постобработки [1] применяются к набору обучающих данных и выходным значениям ИНС автоматически. Для более детальной настройки процесса обучения ИНС рекомендуется пользоваться командной строкой MATLAB, позволяющей задавать все изменяемые параметры создаваемой ИНС по своему усмотрению. Несомненным преимуществом MATLAB является возможность экспортировать реализованную в ней ИНС в Simulink в виде блока модели и использовать совместно с другими блоками, а значит, применять ее в реальном темпе моделирования.

Основная часть

С помощью разработанной в системе MATLAB-Simulink модели части энергосистемы [1, рис. 4] сформированы четыре набора обучающих данных, отличающихся принципом получения входных и соответствующих им выходных значений обучающих пар.

Для первого набора шаг изменения каждого параметра блока, моделирующего питающую эквивалентную систему, подбирался индивидуально, исходя из влияния степени его изменения на получаемую форму искаженного сигнала вторичного тока ТТ. Это позволило получить разнообразные формы вторичного тока ТТ, а также адекватный по размеру набор обучающих данных. Общее количество пар набора составило 86016, т. е. запуск модели осуществлялся 1344 раза, за каждый из которых формировались 64 обучающие пары.

Для второго набора каждая обучающая пара формировалась путем случайного изменения (с произвольным шагом в рамках определенного диапазона) каждого параметра блока, моделирующего питающую эквивалентную систему. Количество пар второго набора примет равным первому – 86016.

Третий набор получили в результате объединения первого и второго наборов обучающих данных. Таким образом, количество обучающих пар третьего набора $86016 \cdot 2 = 172032$.

Четвертый набор данных формировался на основе первого и второго, а именно: в качестве набора, непосредственно используемого для обучения ИНС, применялись все 86016 пар первого набора, а проверочные и тестовые наборы данных подбирались по принципу второго набора, т. е. случайным образом. Для четвертого набора, в отличие от предыдущих трех, применялось принудительное разделение на обучающий, проверочный и тестовый. Для первых трех наборов данных такое разделение осуществлялось автоматически и случайным образом в процессе обучения ИНС в используемом по умолчанию в пакете Neural Network Toolbox соотношении: 70 % от общего числа пар набора – непосредственно для обучения, по 15 % – в качестве проверочного и тестового наборов. Примем указанное соотношение и для четвертого набора, при этом количество пар, непосредственно используемых для обучения ИНС, будет составлять 86016, а количество пар проверочного и тестового наборов – по 18432. Таким образом, общее количество пар четвертого набора 122880.

Вычислительный эксперимент

Каждый набор данных применялся для обучения двух ИНС с 15 и 30 нейронами в скрытом слое (рис. 1), осуществляемого методами ранней остановки (*early stopping* (*ES*)) и регуляризации (*Bayesian regularization* (*BR*)).

Оценку качества обучения ИНС удобно производить путем построения графика зависимости изменения ошибки обучения от количества эпох (числа прогонов всех пар набора данных через ИНС). Критерием ошибки часто выступает среднеквадратическая ошибка *mse*, которая при одном выходе ИНС определяется как

$$mse = \frac{1}{N} \sum_{n=1}^N (i_{2id} - i_2^*)^2,$$

где N – количество пар набора; i_2^* – выходное значение ИНС.

Еще один показатель качества обучения – величина регрессии R , отражающая корреляцию между значениями на выходе ИНС и желаемыми. Числовая характеристика степени корреляции близка к единице, в случае если ИНС удалось аппроксимировать зависимость между входными и желаемыми значениями, и значительно меньше единицы, если ИНС не смогла аппроксимировать искомую зависимость.

При однократном обучении ИНС существует вероятность отыскания локального, а не глобального минимума ошибки *mse* (ввиду, например, неудачно выбранных произвольным образом значений начальных весов и смещений), поэтому обучение каждой ИНС проводилось по 10 раз [5]. Далее из 10 полученных значений *mse* выбиралось минимальное и заносилось в табл. 1 совместно с соответствующими показателями регрессии: для обучающего (R_1), проверочного (R_2) и тестового (R_3) наборов данных применительно к методу *ES* и R_1 , R_3 – для метода *BR*, поскольку для него проверочный набор не требуется. Присвоим каждой обучаемой ИНС цифро-буквенное обозначение (например, для пары, обучаемой на третьем наборе данных по методу *ES* и содержащей в скрытом слое 15 нейронов ИНС, – 3ES15).

Таблица 1

Полученные показатели качества обучения искусственной нейронной сети
Performance indexes of an artificial neural network obtained in the study

№ набора	Методика	15 нейронов				30 нейронов				$mse_{15}/$ mse_{30}
		mse_{15}	R_1	R_2	R_3	mse_{30}	R_1	R_2	R_3	
1	<i>ES</i>	469	0,9949	0,9947	0,9949	262	0,9972	0,9969	0,9969	1,9
	<i>BR</i>	370	0,9960	–	0,9956	90	0,9990	–	0,9989	3,7
2	<i>ES</i>	519	0,9950	0,9949	0,9947	457	0,9956	0,9954	0,9953	1,1
	<i>BR</i>	512	0,9951	–	0,9951	166	0,9984	–	0,9983	3,1
3	<i>ES</i>	643	0,9935	0,9934	0,9932	386	0,9961	0,9959	0,9957	1,7
	<i>BR</i>	523	0,9947	–	0,9945	128	0,9987	–	0,9986	4,1
4	<i>ES</i>	838	0,9910	0,9882	0,9880	473	0,9954	0,9904	0,9900	1,8
	<i>BR</i>	389	0,9959	–	0,9948	134	0,9986	–	0,9981	2,9

Увеличение количества нейронов скрытого слоя с 15 до 30 положительно сказывается на численных показателях качества обучения ИНС –

ошибка mse значительно уменьшается для всех наборов данных (табл. 1). При этом для метода BR ошибка mse в зависимости от набора данных сокращается с 2,9 до 4,1 раза, в то время как для ES – с 1,1 до 1,9 раза.

Для всех обученных ИНС, за исключением $4ES15$, показатель регрессии на тестовом наборе R_3 превысил 0,993. Исходя из высоких значений R_3 , можно заранее предположить, что все рассмотренные ИНС обладают высокой способностью к обобщению и, следовательно, смогут с приемлемой для целей РЗ точностью осуществлять восстановление искаженной формы сигнала вторичного тока ТТ.

В процессе вычислительного эксперимента выполнено обучение ИНС методами ES и BR с 10 нейронами в скрытом слое на тех же четырех наборах обучающих данных. Однако точность восстановления искаженной формы сигнала вторичного тока ТТ такими ИНС оказалась, по сравнению с рассматриваемыми, неудовлетворительной. При обучении ИНС с 40 нейронами в скрытом слое получены результаты, которые практически совпадают с достигнутыми при обучении ИНС с 30 нейронами, вследствие чего увеличение числа нейронов свыше 30 признано нецелесообразным.

В ходе исследования выявлено, что обучение с применением метода ES приводит к крайне нестабильным результатам: значение mse от обучения к обучению одной и той же ИНС может отличаться до 5 раз, что подтверждает необходимость многократного повторного обучения по данному методу с целью получения минимально возможной величины mse . При использовании метода BR разброс значений mse оказывается значительно меньше.

Таким образом, лучшие показатели качества обучения получены для ИНС $1BR30$, худшие – для $4ES15$ (табл. 1). На рис. 2 в логарифмическом масштабе приведены изменения ошибок mse для обучающего, проверочного (только для $4ES15$) и тестового наборов данных указанных ИНС.

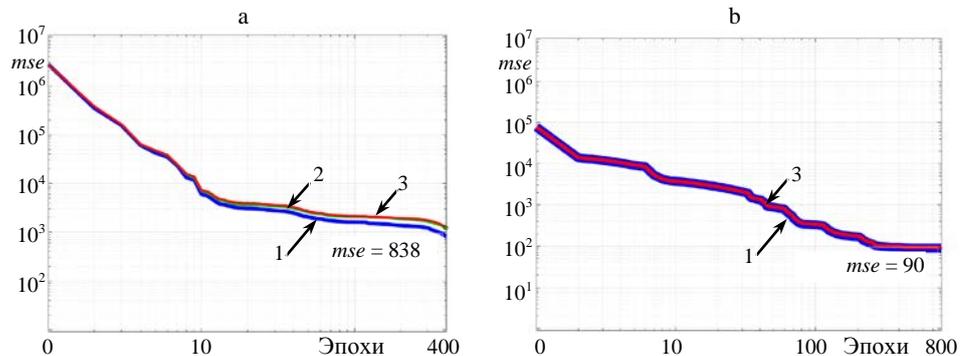


Рис. 2. Изменение ошибки mse в процессе обучения искусственной нейронной сети: а – $4ES15$; б – $1BR30$; 1 – обучающий; 2 – проверочный; 3 – тестовый наборов данных

Fig. 2. Mse error change during training progress: а – $4ES15$; б – $1BR30$; 1 – train dataset; 2 – validation dataset; 3 – test dataset

Примерно до 10-й эпохи происходит резкое снижение ошибки mse ИНС $4ES15$ для всех наборов данных, далее – ее монотонное убывание с небольшими расхождениями между наборами (рис. 2а). В районе 390-й эпохи начинается резкое снижение значения mse на обучающем наборе и одновременно происходит снижение, а затем возрастание ошибки на

проверочном наборе данных (неочевидно из-за логарифмического масштаба графиков), что свидетельствует о начале переобучения ИНС. По прошествии 6 последовательных эпох (число по умолчанию для метода *ES* в пакете *Neural Network Toolbox*), сопровождающихся монотонным увеличением *mse* на проверочном наборе данных, обучение по методу *ES* останавливается и ИНС присваиваются значения весовых коэффициентов и смещений, при которых данная *mse* была минимальной. Ошибка для обучающего набора принимается $mse = 838$.

Остановка обучения и фиксация $mse = 90$ для ИНС *1BR30* (рис. 2b) осуществляется в районе 800-й эпохи при минимизации методом *BR* значений весовых коэффициентов и смещений обучаемой ИНС.

Кривая изменения ошибки тестового набора располагается вплотную к кривым *mse* обучающего и проверочного наборов ИНС *4ES15* (рис. 2a), а для ИНС *1BR30* сливается с кривой изменения *mse* обучающего набора (рис. 2b), т. е. ошибки *mse* на каждом наборе данных примерно одинаковые. Это свидетельствует о достоверности полученных результатов обучения ИНС.

Для наглядной оценки качества обучения приведены графики регрессии R_3 для тестовых наборов ИНС *1BR30* и *4ES15*, на которых каждой паре соответствует одна точка с координатой по оси абсцисс, равной желаемому значению, а по оси ординат – значению на выходе ИНС (рис. 3). При высоком качестве обучения ИНС ее реальные выходные и желаемые значения из тестового набора должны практически совпадать, а соответствующие им точки располагаться вдоль выходящей из начала координат под углом 45° прямой.

Числовая характеристика регрессии для тестовых наборов ИНС *4ES15* $R_3 = 0,9880$, *1BR30* $R_3 = 0,9989$. Близость значений R_3 к единице свидетельствует о том, что обе ИНС аппроксимировали искомую нелинейную зависимость и обладают высокой способностью к обобщению. Однако кучность расположения точек вдоль наклонной прямой у ИНС *4ES15* меньше, что свидетельствует о худших показателях качества обучения по сравнению с *1BR30*, для которой значения на выходе практически совпадают с желаемым (рис. 3). Иными словами, если какая-либо точка на графике регрессии значительно отклонена от наклонной прямой, значит, для данной пары тестового набора ИНС не смогла правильно определить выход.

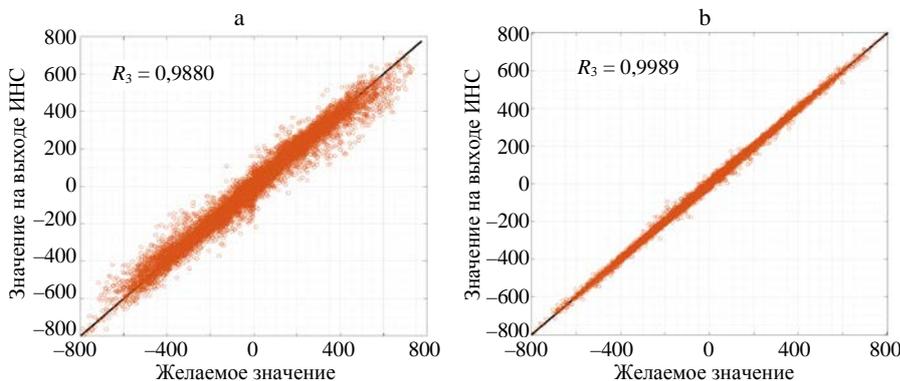


Рис. 3. График регрессии для тестового набора искусственной нейронной сети:
a – *4ES15*; b – *1BR30*

Fig. 3. Regression plot for the test dataset: a – *4ES15*; b – *1BR30*

Рассмотрим функционирование полученных ИНС на примере их использования для восстановления искаженной формы сигнала вторичного тока ТТ вследствие его насыщения. Для каждого набора обучающих данных выбраны ИНС с лучшими и худшими показателями качества обучения. Параметры модели ТТ и диапазон изменений параметров энергосистемы приняты такими же, как и при формировании наборов обучающих данных [1]. Дополнительно для ТТ изменялось значение остаточной намагниченности его магнитопровода $B_{ост}$ в диапазоне 0–0,8 Тл.

На рис. 4 приведена разработанная в системе MATLAB-Simulink с использованием блоков пакета расширения SimPowerSystems модель части энергосистемы, в которой имитируется режим насыщения ТТ, сопровождающийся искажением формы сигнала его вторичного тока, и ее последующее восстановление рассмотренными выше ИНС. Обученные в Neural Network Toolbox ИНС экспортированы в Simulink в виде блоков их моделей – Neural network. На вход Input блока ИНС поступают выборки сигнала искаженного вторичного тока ТТ, а на выходе Output формируется соответствующее им восстановленное значение вторичного тока. Далее сигнал восстановленного вторичного тока ТТ поступает на осциллограф Scope и на вход Input блока цифрового фильтра Digital filter, где на выходе RMS формируется действующее значение основной (первой) гармоники указанного сигнала, также поступающее на осциллограф Scope. Описание остальных блоков модели приведено в [1].

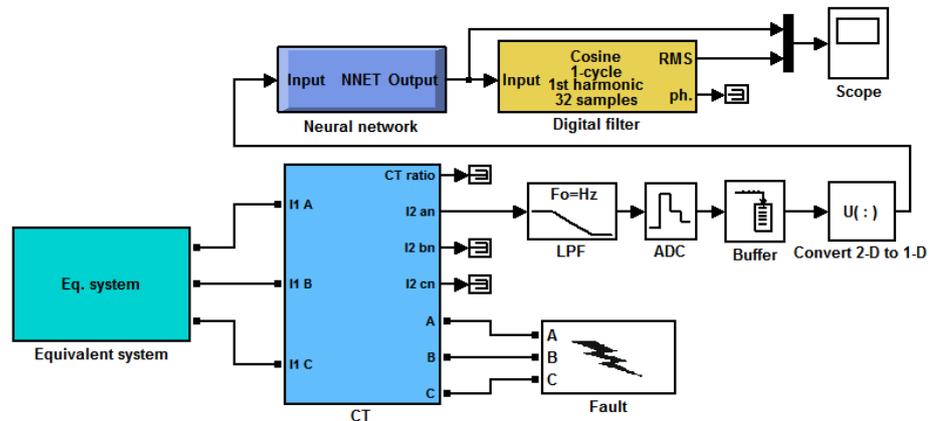


Рис. 4. Разработанная в MATLAB-Simulink модель для восстановления с использованием искусственной нейронной сети формы сигнала искаженного вторичного тока трансформатора тока

Fig. 4. MATLAB-Simulink based model for a current transformer distorted secondary current waveform reconstruction using artificial neural networks

Результаты исследований представлены на рис. 5–8.

ИНС позволяют практически полностью восстановить искаженную форму сигнала вторичного тока ТТ до ее идеального (истинного) значения в широком диапазоне изменения параметров энергосистемы. Несмотря на существенное отличие ошибки *mse* (от 3,12 до 6,25 раза) ИНС с худшими и лучшими показателями качества обучения для каждого набора обучающих данных, точность восстановления сигналов существенно не изменяется.

При этом разница вычисляемых действующих значений основных гармоник восстановленных вторичных токов по сравнению с их истинным действующим значением ни в одном из рассмотренных случаев не превышает 10 %.

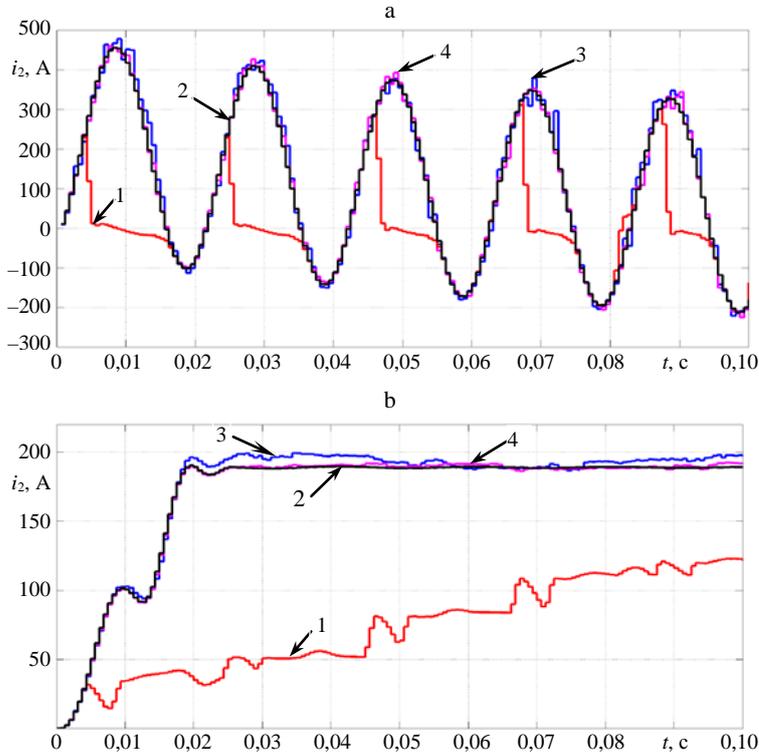


Рис. 5. Сравнение результатов восстановления искаженной формы вторичного тока трансформатора тока при $I_{сз} = 22705$ А, $\varphi = 35^\circ$, $\tau = 0,071$ с, $B_{ост} = 0,165$ Тл:
а – мгновенные значения; б – действующие значения основной гармоники;
1, 2 – реальный и идеальный вторичные токи; 3 – восстановленный 1ES15 вторичный ток;
4 – восстановленный 1BR30 вторичный ток

Fig. 5. Comparison of the current transformer distorted secondary current waveform reconstruction results at $I_{sc} = 22705$ A, $\varphi = 35^\circ$, $\tau = 0.071$ s, $B_{rem} = 0.165$ T:
а – instantaneous values; б – RMS values of the fundamental frequency component;
1, 2 – real and ideal secondary current; 3 – reconstructed by 1ES15 secondary current;
4 – reconstructed by 1BR30 secondary current

Насыщение ТТ приводит к тому, что его реально протекающий вторичный ток имеет характерную искаженную форму (рис. 5а, 6а, 7а, 8а, кривая 1), существенно отличающуюся от идеальной формы (рис. 5а, 6а, 7а, 8а, кривая 2), т. е. от такой, ток которой протекал бы во вторичных цепях ТТ и подводился к устройствам РЗ при отсутствии насыщения. В результате происходит занижение вычисляемого цифровым фильтром в составе устройства РЗ действующего значения основной гармоники реально протекающего вторичного тока (рис. 5б, 6б, 7б, 8б, кривая 1) по сравнению с ее идеальным действующим значением (рис. 5б, 6б, 7б, 8б, кривая 2).

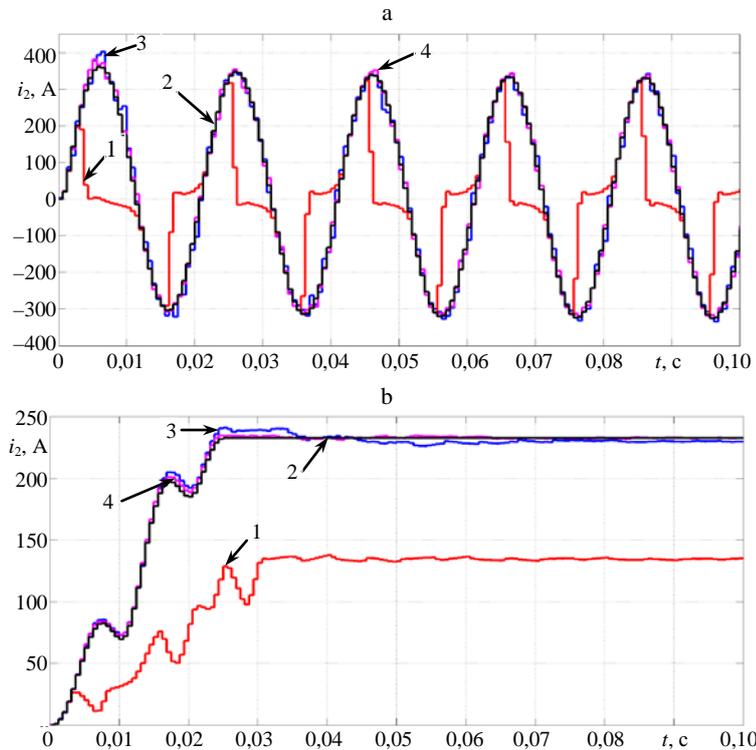


Рис. 6. Сравнение результатов восстановления искаженной формы вторичного тока трансформатора тока при $I_{кз} = 28044$ А, $\varphi = 78^\circ$, $\tau = 0,035$ с, $B_{ост} = 0,053$ Тл: а, б, 1, 2 – то же, что и на рис. 5; 3 – 2ES15; 4 – 2BR30

Fig. 6. Comparison of the current transformer distorted secondary current waveform reconstruction results at $I_{sc} = 28044$ А, $\varphi = 78^\circ$, $\tau = 0.035$ s, $B_{rem} = 0.053$ T: а, б, 1, 2 – the same as in the Fig. 5; 3 – 2ES15; 4 – 2BR30

Таким образом, вычисляемое действующее значение основной гармоники реального вторичного тока если и достигает своего идеального значения (что соответствует моменту времени выхода ТТ из режима насыщения), то это происходит на 5 и более периодов промышленной частоты позже, чем вычисляемое действующее значение сигнала вторичного тока, восстановленного любой из рассмотренных ИНС (рис. 5б, 6б, 7б, 8б, кривые 3, 4). При этом традиционными микропроцессорными устройствами токовой РЗ вычисляются именно действующие значения основной гармоники реального вторичного тока, что приводит к значительному затягиванию времени срабатывания РЗ или вовсе к отказу ее функционирования при насыщении ТТ [1]. Указанное происходит ввиду того, что действующее значение может быть значительно ниже заданных уставок срабатывания, которые, в свою очередь, рассчитываются исходя из условия идеальной трансформации (насыщение ТТ не учитывается) первичного тока повреждения во вторичные цепи ТТ (рис. 5а, 6а, 7а, 8а, кривая 2).

Использование ИНС для целей восстановления искаженного вторичного тока ТТ в устройствах РЗ позволит их цифровым фильтрам осуществлять вычисление такого действующего значения основной гармоники вос-

становленного сигнала вторичного тока ТТ, которое будет максимально приближено к своему идеальному значению, что обеспечит повышение быстродействия и надежности функционирования устройств РЗ по сравнению с их традиционной реализацией.

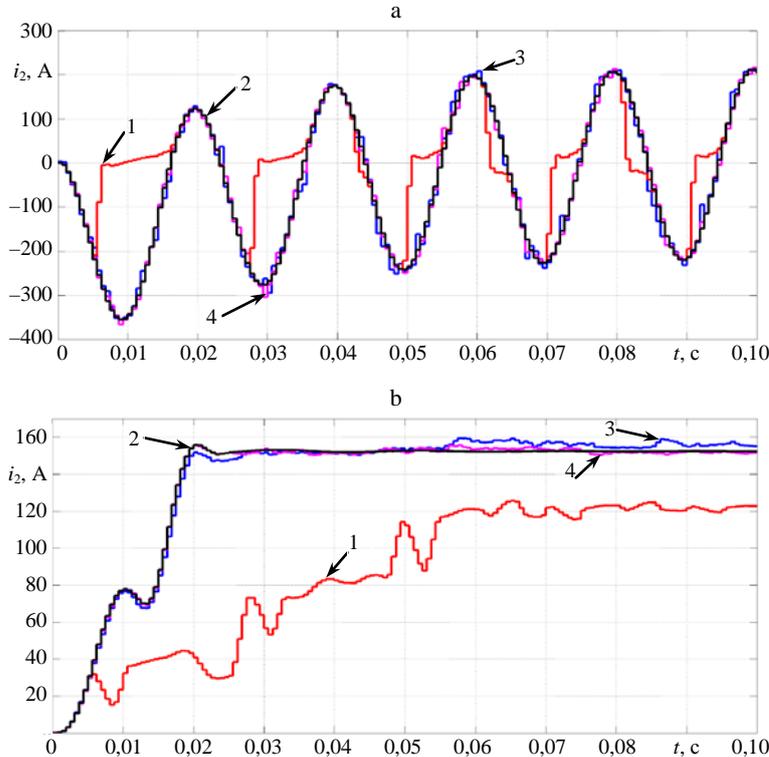


Рис. 7. Сравнение результатов восстановления искаженной формы вторичного тока трансформатора тока при $I_{кз} = 18451$ А, $\varphi = 195^\circ$, $\tau = 0,024$ с, $B_{ост} = 0,023$ Тл: а, б, 1, 2 – то же, что и на рис. 5; 3 – 3ES15; 4 – 3BR30

Fig. 7. Comparison of the current transformer distorted secondary current waveform reconstruction results at $I_{sc} = 18451$ A, $\varphi = 195^\circ$, $\tau = 0.024$ s, $B_{rem} = 0.023$ T: а, б, 1, 2 – the same as in the Fig. 5; 3 – 3ES15; 4 – 3BR30

Даже если восстановленный ИНС сигнал имеет выбросы или не точно следует форме идеального вторичного тока ТТ, оценивать качество функционирования и применимость такой ИНС следует именно по вычисляемым действующим значениям основной гармоники восстановленного сигнала, поскольку на основании результатов сравнения именно действующего значения с уставкой устройства РЗ приходят в действие. В связи с этим можно сделать вывод, что наиболее удобным и информативным показателем оценки качества обучения ИНС является значение регрессии тестового набора R_3 . Согласно результатам вычислительного эксперимента и данным табл. 1, приемлемая точность восстановления вторичного тока ТТ обеспечивается при $R_3 > 0,9900$. Это свидетельствует о том, что все предложенные способы формирования наборов обучающих данных могут быть успешно использованы в процессе обучения ИНС.

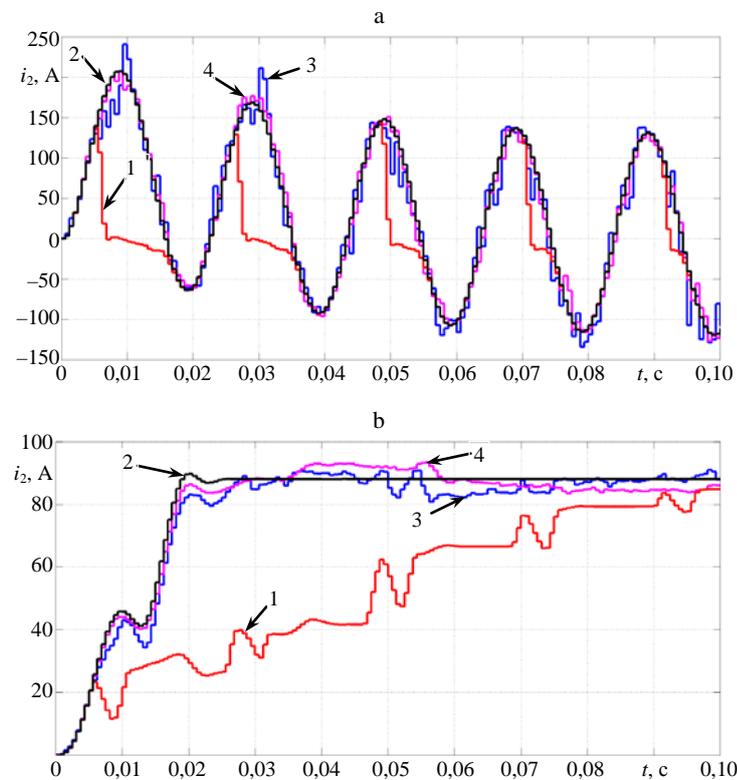


Рис. 8. Сравнение результатов восстановления искаженной формы вторичного тока трансформатора тока при $I_{кз} = 10628$ А, $\varphi = 24^\circ$, $\tau = 0,032$ с, $B_{ост} = 0,454$ Тл: а, б, 1, 2 – то же, что и на рис. 5; 3 – 4ES15; 4 – 4BR30

Fig. 8. Comparison of the current transformer distorted secondary current waveform reconstruction results at $I_{sc} = 10628$ A, $\varphi = 24^\circ$, $\tau = 0.032$ s, $B_{rem} = 0.454$ T: а, б, 1, 2 – the same as in the Fig. 5; 3 – 4ES15; 4 – 4BR30

Наилучшие показатели качества обучения достигнуты для ИНС 1BR30 с использованием первого набора данных. Обучающий набор сигналов получен путем изменения значений параметров модели (с выбранным шагом в рамках определенного диапазона), влияющих на форму сигнала. Тем самым достигается равномерная оцифровка всего диапазона изменения форм сигнала вторичного тока, что положительно сказывается на показателях качества обучения ИНС.

При невозможности априорной оценки влияния величины шага изменения параметров модели на форму получаемого сигнала оправданным является использование способа, применявшегося для формирования второго набора обучающих данных и заключающегося в случайном изменении (в рамках определенного диапазона) шага значений параметров модели, влияющих на форму получаемого сигнала.

Использование остальных рассмотренных способов формирования наборов обучающих данных не привело к существенному повышению показателей качества обучения.

Исходя из вышеизложенного, рекомендуется применять способы формирования первого и второго наборов обучающих данных и регуляризацию (*BR*) как метод обучения.

Отметим еще одну важную и неочевидную особенность. Рассмотренные ИНС могут применяться для восстановления вторичного тока не только ТТ1, с использованием которого получены наборы обучающих данных, но и ТТ2 с отличным от ТТ1 коэффициентом трансформации. Основное условие заключается в том, чтобы действующее значение тока повреждения $I_{кз}$ находилось в диапазоне $(0,5I_{ном}K_{ном} - 3I_{ном}K_{ном})$ А, где значение параметра $I_{ном}$ относится к ТТ2, а параметр $K_{ном}$ – к ТТ1 [1].

Сравним функционирование ИНС *1BR30* с лучшими и *4ES15* с худшими показателями качества обучения на примере восстановления ими искаженного вторичного тока ТТ2 с $I_{ном} = 300$ А (рис. 9). Остальные вторичные параметры приняты такими же, как и для рассмотренного выше ТТ1 с $I_{ном} = 600$ А.

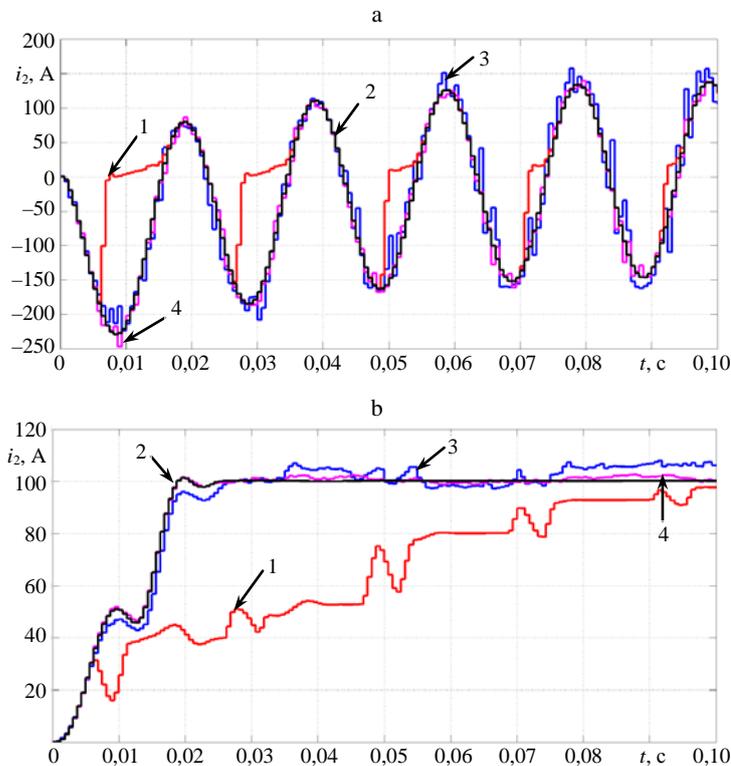


Рис. 9. Сравнение результатов восстановления искаженной формы вторичного тока трансформатора тока с $I_{ном} = 300$ А при $I_{кз} = 6044$ А, $\varphi = 209^\circ$, $\tau = 0,029$ с, $B_{ост} = 0,221$ Тл:
а, б, 1, 2 – то же, что и на рис. 5; 3 – 4ES15; 4 – 1BR30

Fig. 9. Comparison of the current transformer with $I_{ном} = 300$ А distorted secondary current waveform reconstruction results at $I_{кз} = 6044$ А, $\varphi = 209^\circ$, $\tau = 0.029$ s, $B_{rem} = 0.221$ T:
а, б, 1, 2 – the same as in the Fig. 5; 3 – 4ES15; 4 – 1BR30

Как видно из рис. 9, обе ИНС успешно произвели восстановление формы сигнала вторичного тока ТТ2 с отличным от ТТ1 коэффициентом

трансформации. Вычисляемые действующие значения основных гармоник восстановленных вторичных токов, как и на рис. 5–8, отличаются не более чем на 10 % от истинных действующих значений.

Для успешного применения ИНС в реальных условиях эксплуатации устройств РЗ ее обучение должно осуществляться на формах сигнала вторичного тока ТТ, максимально приближенных к реальным. В связи с этим модель ТТ для формирования набора обучающих данных должна точно воспроизводить как моменты входа и выхода ТТ из насыщения, так и форму сигнала вторичного тока между ними. Точность в основном зависит от способа задания нелинейных свойств магнитопровода, определяемых характеристикой намагничивания. Например, при использовании прямоугольной характеристики намагничивания (ПХН) или спрямленной характеристики намагничивания (СХН) [19] вторичный ток ТТ между участками точной трансформации будет спадать скачкообразно, и точка выхода из насыщения всегда будет располагаться на его положительных полуволнах, что не соответствует его реальной (плавно затухающей) форме. Указанное происходит из-за того, что при аппроксимации реальной характеристики намагничивания по методу ПХН и СХН участок области насыщения заменяется горизонтальной прямой, что равносильно замене в схеме замещения ТТ его ветви намагничивания идеальным ключом без индуктивностей, который и обуславливает возможность скачкообразного изменения вторичного тока ТТ.

Учет нелинейных свойств магнитопровода в модели ТТ должен осуществляться путем кусочно-линейной аппроксимации средней характеристики намагничивания (или иной пропорциональной ей характеристики) [20], либо следует проводить полноценное моделирование явления гистерезиса [21, 22], что позволяет реалистично воспроизводить форму сигнала вторичного тока ТТ при насыщении его магнитопровода. Даже аппроксимация двумя наклонными прямыми с правильно выбранным наклоном второй прямой в области глубокого насыщения позволяет получать реалистичные результаты [23]. Модель ТТ также должна отражать реальную схему их соединений, так как в действительности к устройствам РЗ подводятся вторичные токи от трехфазной группы ТТ, соединенных по схеме «звезда с нулевым проводом». Вторичные токи данной группы ТТ при некоторых видах повреждений, сопровождающихся насыщением ТТ, отличаются по форме от вторичных токов одиночных ТТ при тех же условиях [24–26].

ИНС, разработанные в специализированных средах моделирования, например MATLAB, могут транслироваться в оптимизированные для микропроцессоров машинные коды и впоследствии использоваться в реальных устройствах РЗ для цифровой обработки сигналов и построения усовершенствованных алгоритмов их функционирования.

ВЫВОДЫ

1. Показано, что искусственные нейронные сети могут успешно использоваться для восстановления искаженной формы сигнала вторичного тока трансформатора тока вследствие насыщения его магнитопровода с приемлемой для целей релейной защиты точностью.

2. На основании полученных результатов вычислительного эксперимента установлены оптимальные способы формирования набора обучающих данных искусственной нейронной сети и метод ее обучения.

3. Определены требования, предъявляемые к модели трансформатора тока, используемой для формирования набора обучающих данных искусственной нейронной сети.

4. Разработанные искусственные нейронные сети могут использоваться в реальных устройствах релейной защиты для цифровой обработки сигналов и построения усовершенствованных алгоритмов их функционирования.

ЛИТЕРАТУРА

1. Румянцев, Ю. В. Разработка в MATLAB-Simulink искусственной нейронной сети для восстановления искаженной формы вторичного тока. Ч. 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>.
2. Haykin, S. *Neural Networks and Learning Machines* / S. Haykin; 3rd Ed. New Jersey: Pearson Education Inc., 2009. 936 p. <https://doi.org/10.1007/BF02551274>.
3. Cybenko, G. Approximation by Superpositions of a Sigmoidal Function / G. Cybenko // *Mathematics of Control, Signals, and Systems*. 1989. Vol. 2. P. 303–314. <https://doi.org/10.1007/BF02551274>.
4. *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.
5. *Neural Network Design* / M. T. Hagan [et al.], 2nd Ed. Boston: PWS Publishing, 2014. 1012 p.
6. Медведев, В. С. Нейронные сети. *MatLab 6* / В. С. Медведев, В. Г. Потемкин. М.: Диалог-МИФИ, 2002. 496 с.
7. 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>.
8. 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>.
9. 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>.
10. 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>.
11. 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>.
12. Rebizant, W. *Digital Signal Processing in Power System Protection and Control* / W. Rebizant, J. Szafran, A. Wiszniewski. London: Springer, 2011. 316 p. <https://doi.org/10.1007/978-0-85729-802-7>.
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*. 2001. 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*. 2006. Vol. 21, Iss. 1. P. 73–79. <https://doi.org/10.1109/TPWRD.2005.858799>.
15. 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.

16. Haghjoo, F. Compensation of CT Distorted Secondary Current Waveform in Online Conditions / F. Haghjoo, M. H. Pak // *IEEE Transactions on Power Delivery*. 2016. Vol. 31, Iss. 2. P. 711–720. <https://doi.org/10.1109/TPWRD.2015.2448634>.
17. 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>.
18. 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/PSS.2000.868725>.
19. Электрические цепи с ферромагнитными сердечниками в релейной защите / А. Д. Дроздов [и др.]. М.: Энергоатомиздат, 1986. 255 с.
20. Kojovic, L. A. Comparison of Different Current Transformer Modeling Techniques for Protection System Studies / L. A. Kojovic // *Power Engineering Society Summer Meeting*. 2002. Vol. 3. P. 1084–1089. <https://doi.org/10.1109/PSS.2002.1043427>.
21. Annakkage, U. D. A Current Transformer Model Based on the Jiles-Atherton Theory of Ferromagnetic Hysteresis / U. D. Annakkage, P. G. McLaren // *IEEE Transactions on Power Delivery*. 2000. Vol. 1, Iss. 1. P. 57–61. <https://doi.org/10.1109/61.847229>.
22. Lucas, J. R. Simulation of BH Excursions for Transient Studies / J. R. Lucas, P. G. McLaren // *Proceedings of the 33rd Midwest Symposium on Circuits and Systems*. 1990. P. 370–373. <https://doi.org/10.1109/MWSCAS.1990.140730>.
23. Kezunovic, M. Experimental Evaluation of EMTP-Based Current Transformer Models for Protective Relay Transient Study / M. Kezunovic, L. A. Kojovic // *IEEE Transactions on Power Delivery*. 1994. Vol. 9, Iss. 1. P. 405–413. <https://doi.org/10.1109/61.277712>.
24. Prochazka, M. Modeling of Current Transformers under Saturation Conditions / M. Prochazka // *Advances in Electrical and Electronic Engineering*. 2011. Vol. 5, Iss. 1. P. 94–97.
25. 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.
26. Испытания микропроцессорных токовых защит: теория, моделирование, практика / И. В. Новаш [и др.]. Минск: БНТУ, 2021. 168 с.

Поступила 29.10.2021 Подписана в печать 27.12.2021 Опубликована онлайн 31.01.2022

REFERENCES

1. 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. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 64 (6), 479–491. <https://doi.org/10.21122/1029-7448-2021-64-6-479-491> (in Russian).
2. Haykin S. (2009) *Neural Networks and Learning Machines*. 3rd Ed. Pearson Education Inc. 936.
3. Cybenko G. (1989) Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals, and Systems*, 2, 303–314. <https://doi.org/10.1007/BF02551274>.
4. *Neural Network Toolbox. User's Guide. Version 4* (2002). The MathWorks. Available at: http://cda.psych.uiuc.edu/matlab_pdf/nnet.pdf.
5. Hagan M. T., Demuth H. B., Bale M. H., De Jesus O. (2014) *Neural Network Design*. 2nd Ed. Boston: PWS Publishing. 1012.
6. Medvedev V. S., Potemkin V. G. (2002). *Neural Networks. MatLab 6*. Moscow, Dialog-MIFI Publ. 496. (in Russian).
7. 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).
8. 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 Equipment. *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).
9. 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>.
 10. 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>.
 11. 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>.
 12. Rebizant W., Szafran J., Wiszniewski A. (2011) *Digital Signal Processing in Power System Protection and Control*. London, Springer Publ. 316. <https://doi.org/10.1007/978-0-85729-802-7>.
 13. Yu D. C., Cummins J. C., Wang Zh., Yoon H.-J., Kojovic L. A. (2001) 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. (2006) 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. 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.
 16. Haghjoo F., Pak M. H. (2016) 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>.
 17. 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>.
 18. 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>.
 19. Drozdov A. D., Zasyplin A. S., Kuzhekov S. L., Platonov V. V., Podgornyi E. V. (1986) *Electric Circuits with Ferromagnetic Cores in Relay Protection*. Moscow, Energoatomizdat Publ. 255 (in Russian).
 20. Kojovic L. A. (2002) Comparison of Different Current Transformer Modeling Techniques for Protection System Studies. *Power Engineering Society Summer Meeting*, 3, 1084–1089. <https://doi.org/10.1109/PESS.2002.1043427>.
 21. Annakkage U. D., McLaren P. G. (2000) A Current Transformer Model Based on the Jiles-Atherton Theory of Ferromagnetic Hysteresis. *IEEE Transactions on Power Delivery*, 1 (1), 57–61. <https://doi.org/10.1109/61.847229>.
 22. Lucas J. R., McLaren P. G. (1990) Simulation of BH Excursions for Transient Studies. *Proceedings of the 33rd Midwest Symposium on Circuits and Systems*, 370–373. <https://doi.org/10.1109/MWSCAS.1990.140730>.
 23. Kezunovic M., Kojovic L. A. (1994) Experimental Evaluation of EMTP-Based Current Transformer Models for Protective Relay Transient Study. *IEEE Transactions on Power Delivery*, 9 (1), 405–413. <https://doi.org/10.1109/61.277712>.
 24. Prochazka M. (2011) Modeling of Current Transformers under Saturation Conditions. *Advances in Electrical and Electronic Engineering*, 5 (1), 94–97.
 25. 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).
 26. Novash I. V., Romaniuk F. A., Rumiantsev V. Yu., Rumiantsev Yu. V. (2021) *Testing of Microprocessor Current Protections: Theory, Modeling, Practice*. Minsk, BNTU. 168 (in Russian).