

УДК 621.316.91

DOI: 10.22213/2413-1172-2023-2-76-84

Нейросетевой программно-аппаратный контроль сдвига фаз электрических сигналов в реальном времени

О. Н. Андреев, аспирант, Чувашский государственный университет имени И. Н. Ульянова, Чебоксары, Россия
А. Л. Славутский, кандидат технических наук, ООО «Юнител Инжиниринг», Чебоксары, Россия

Аппарат искусственных нейронных сетей все чаще применяется в интеллектуальной электроэнергетике. Интеллектуальные сети являются одним из ключевых компонентов цифровой экономики. Цель работы – показать возможность использования искусственной нейронной сети простой архитектуры в соответствующей микропроцессорной технике для улучшения таких характеристик микропроцессорных устройств, как уменьшение времени реакции устройства, повышение точности принятия решений при возникновении аварийной ситуации и возможность более точно локализовать место аварии. Это позволяет уменьшить негативные последствия аварии, сократить время для определения места аварии и, соответственно, существенно сократить время на устранение последствий аварии, восстановление нормального режима работы энергосистемы. Обучение нейросети – процесс длительный. При этом даже глубокое обучение нейронных сетей не гарантирует отсутствие значительных ошибок при их использовании. Поэтому предлагается занесение уже обученной нейронной сети в интеллектуальные электронные устройства в том случае, когда электрические сигналы могут быть описаны аналитическими формулами и диапазоны возможного варьирования параметров таких сигналов заданы заранее. Соответствующий подход реализован и протестирован в микропроцессорном устройстве для быстрой оценки сдвига фаз сигналов в переходных режимах. Показано, что оценка разности фаз может быть проведена за время, не превышающее 1 мс, что значительно превосходит возможности традиционных алгоритмов на основе фильтра Фурье. Обсуждаются возможности практического применения и совместного использования фильтра Фурье и аппарата искусственных нейронных сетей для создания гибридных измерительных органов устройств релейной защиты. Подход и полученные результаты потенциально могут быть применимы в широком круге задач обработки сигналов.

Ключевые слова: искусственная нейронная сеть, микроконтроллер, микропроцессор, обработка сигналов, аварийный режим, релейная защита.

Введение

В последние годы искусственные нейронные сети (ИНС) всё чаще применяются для решения сложных задач обработки данных и сигналов в реальном времени – от распознавания образов и классификации данных до идентификации и контроля нелинейных систем и процессов [1–3]. Это, прежде всего, обусловлено способностью ИНС аппроксимировать непрерывные нелинейные функции с желаемой точностью [4–6]. В электротехнике свое применение ИНС находят в системах управления напряжением батарей питания [7], управлении электрическими двигателями [8–11]. Аппарат искусственных нейронных сетей всё чаще используется и в задачах релейной защиты и автоматизации [12, 13]. В первую очередь это связано с активными действиями по внедрению цифровых подстанций и интеллектуальных

электрических сетей (Smart Grid) [14]. Технологии Smart Grid активно разрабатываются и внедряются электросетевыми компаниями. Одним из основных направлений использования элементов искусственного интеллекта [15, 16] и ИНС в частности является анализ данных для предсказания потребления электроэнергии, распределения электрической нагрузки и потерь электроэнергии в сетях [17]. Помимо этого нейронные сети используются для анализа и прогнозирования параметров режимов работы электрических сетей, их технологических характеристик [18], диагностики и локализации неисправностей [19]. Например, ИНС могут применяться для диагностики неисправностей силовых трансформаторов [20], распознавания аномальных режимов систем вторичного оборудования, верификации топологии электрической сети для правильного определения места по-

вреждения, для управления возобновляемой электрогенерацией.

Интеллектуализация электрических сетей подразумевает, в том числе, использование интеллектуальных электронных устройств (ИЭУ) – нового поколения многофункциональных микропроцессорных устройств. В состав ИЭУ входят микропроцессоры, цифровые и аналоговые датчики и средства автоматизации. Данный факт позволяет реализовывать ИНС непосредственно в ИЭУ. ИНС могут использоваться в ИЭУ для цифровой обработки сигнала [21–23].

Самой распространенной ИНС является многослойный персептрон [24], который благодаря своей простой структуре в основном применяется для решения задач аппроксимации и интерполяции. Многослойный персептрон – ИНС с прямым распространением сигнала (без обратных связей), которая обучается с «учителем». Использование персептрона позволяет аппроксимировать непрерывные функции с высокой точностью. Для широкого круга задач аппроксимации в такой ИНС достаточно одного скрытого слоя нейронов с сигмоидной функцией активации.

При реализации персептрона, как и любой ИНС, основной проблемой является качество обучения [25]. Информация, которую персептрон имеет о задаче, содержится в наборе примеров для обучения, поэтому размер обучающей выборки и ее качество (диапазон случайного варьирования входных параметров и др.) определяет точность работы ИНС. При этом качество обучения ИНС прямого распространения не зависит от последовательности, в которой сигналы обучающей выборки подаются на ее вход.

Качество и точность работы ИНС также зависят от правильного выбора структуры ИНС: количества промежуточных слоев и количества нейронов в каждом слое, выбора целевых функций на выходе сети. В самом простом варианте персептрон состоит минимум из 3 слоев: входные нейроны, промежуточный (скрытый, ассоциативный) слой, выходные нейроны. Существуют рекомендации по выбору количества скрытых слоев и нейронов, но в большинстве случаев требуемая конфигурация нейросети для каждой конкретной задачи подбирается опытным путем.

Цель работы – показать возможность использования искусственной нейронной сети простой архитектуры в соответствующей микропроцессорной технике для улучшения таких характеристик микропроцессорных устройств, как уменьшение времени реакции устройства,

повышение точности принятия решений при возникновении аварийной ситуации и возможность более точно локализовать место аварии.

Приведена реализация ИНС прямого распространения в ИЭУ для решения задач электроэнергетического комплекса на примере определения в реальном времени разности фаз между двумя аналоговыми сигналами (например, между током и напряжением).

Материалы и методы

Протестирована модель простейшей нейронной сети прямого распространения. Обучение нейронной сети в микропроцессорном устройстве непосредственно на объекте в реальных условиях не может гарантировать достаточную точность ее работы и даже приводить к неправильной работе ИЭУ. Это связано прежде всего с тем, что невозможно предугадать и воссоздать все возможные режимы работы энергообъекта. Но в случае, когда сигналы промышленной частоты могут быть заданы простыми аналитическими формулами, имеются оценки всего возможного диапазона варьирования параметров сигналов; структура ИНС очень простая, и она может быть заранее обучена и занесена в микропроцессорное устройство. Так как моделирование и проверка работы ИНС – процесс длительный и ресурсоемкий, эти этапы были проведены на компьютере.

Структура использованной ИНС представлена на рисунке 1. На вход нейросети подаются дискретизированные с частотой 2400 Гц отсчеты двух аналоговых сигналов $S_1 = (t)$ и $S_2 = (t)$, между которыми предполагается определять разность фаз. На выходе нейросети – значение разности фаз. Промежуточный слой состоит из 20 нейронов.

ИНС обучалась по традиционному алгоритму обратного распространения ошибки. Обучающая и тестовая выборки состояли из 10 тыс. сигналов, которые задавались в следующем простейшем виде:

$$S_1(t) = I_1 \sin(2\pi ft + \varphi_i);$$

$$S_2(t) = U_1 \sin(2\pi ft + \varphi_u),$$

где случайные параметры I_1 и U_1 принимают значения от 0 до 12 о.е., f – от 45 до 55 Гц, φ_i и φ_u – от 0 до $\pi/2$.

При этом разность фаз между сигналами $S_1 = (t)$ и $S_2 = (t)$ определяется как

$$\Delta\varphi = \varphi_u - \varphi_i$$

и не превышает значение $\pi/2$.

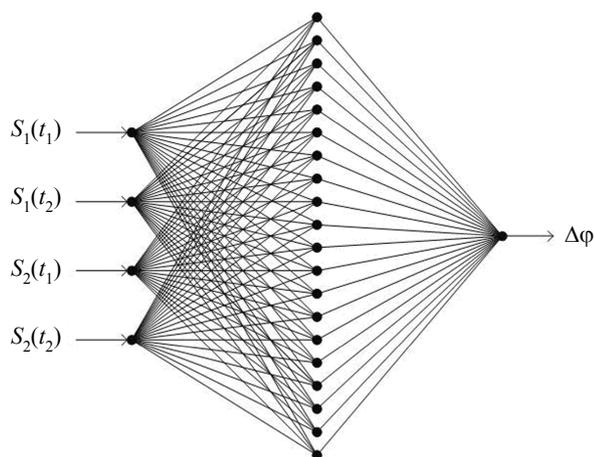


Рис. 1. Структура ИНС для контроля сдвига фаз между двумя сигналами

Fig. 1. The ANN structure for controlling the phase shift between two signals

Обученная и протестированная ИНС была реализована в микроконтроллере на базе открытой и свободно используемой архитектуры RISC (Reduced Instruction Set Computer) с тактовой частотой работы до 100 МГц в составе отладочного комплекта. Аналогово-измеритель-

ный тракт был собран на компонентной базе, используемой в серийном микропроцессорном устройстве. Тестовый стенд схематично изображен на рисунке 2.

Тестовый стенд состоит из измерительного трансформатора тока и измерительного трансформатора напряжения, являющихся аналоговыми входами стенда; внешнего многоканального АЦП (ADC); микроконтроллера (CPU), базирующегося на ядре RISC с тактовой частотой 100 МГц.

Аналоговые сигналы $S_1 = (t)$ и $S_2 = (t)$ для имитации аварийного режима с резким изменением фазы сигналов подавались на вход стенда с помощью программно-аппаратного комплекса РЕТОМ. Сигналы $S_1 = (t)$ и $S_2 = (t)$, предварительно обработанные аналогово-измерительным трактом тестового стенда, подаются на вход ИНС в режиме скользящего окна. Временной интервал, соответствующий длительности скользящего окна, определяется двумя выборками каждого сигнала и составляет 0,817 мс. Время, затраченное микроконтроллером на работу ИНС в потоке, и сопутствующую обработку аппаратных прерываний, не превышает 100 мкс.

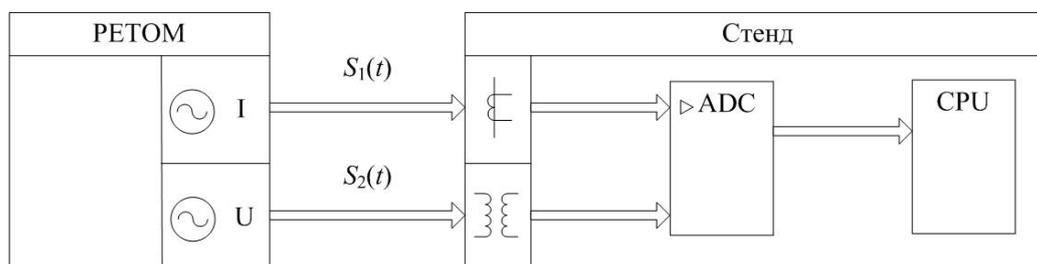


Рис. 2. Схема тестового стенда на базе микроконтроллера с ядром RISC

Fig. 2. The test bench based on a RISC core microcontroller scheme

Далее обученная и протестированная ИНС (набор полученных весовых коэффициентов и постоянных смещения нейронов) перенесена в готовое микропроцессорное устройство релейной защиты среднего напряжения с микроконтроллером на базе ядра Cortex-M с тактовой частотой 216 МГц. В данном устройстве уже присутствуют аналоговые каналы тока и напряжения, достаточно лишь написать программу для обработки готовых нормализованных аналоговых величин с канала тока и с канала напряжения.

Время работы приложения в микропроцессорном устройстве без применения оптимизации кода реализации ИНС для определения $\Delta\varphi$ двух сигналов $S_1 = (t)$ и $S_2 = (t)$ в потоке составило порядка 65 мкс, что в целом сопоставимо

со временем работы приложения для получения ортогональных составляющих в векторной форме одного аналогового сигнала с помощью фильтра Фурье.

Результаты

На рисунке 3 показана гистограмма распределения ошибок при обучении ИНС (см. рис. 1) для контроля сдвига фаз между двумя сигналами. Как видно из гистограммы, среднеквадратичная погрешность определения величины сдвига фаз между двумя сигналами в 87 % случаях не превышает 3,6 % от диапазона варьирования $\Delta\varphi$.

Такая точность, полученная после подбора структуры персептрона при обучении, позволила занести ИНС в микроконтроллер для обработки сигнала.

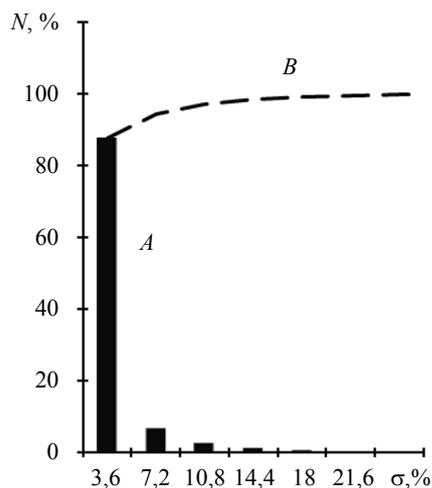


Рис. 3. Гистограмма распределения ошибок на выходе ИНС для контроля сдвига фаз между двумя сигналами (A) и сумма с накоплением (B)

Fig. 3. Histogram of the error distribution at the output of the ANN for controlling the phase shift between two signals (A) and accumulated amount (B)

На рисунке 4 представлен один из вариантов тестовых аналоговых сигналов, поданных на вход ИНС. Изначально характеристики сигналов следующие: $I_1 = 2$ о.е.; $U_1 = 10$ о.е.; $f = 50$ Гц; $\Delta\phi = \pi/12$. В момент времени $t = 9,1$ мс параметры сигналов начинают принимать следующие значения: $I_1 = 10$ о.е.; $U_1 = 8$ о.е.; $f = 50$ Гц; $\Delta\phi = \pi/3$.

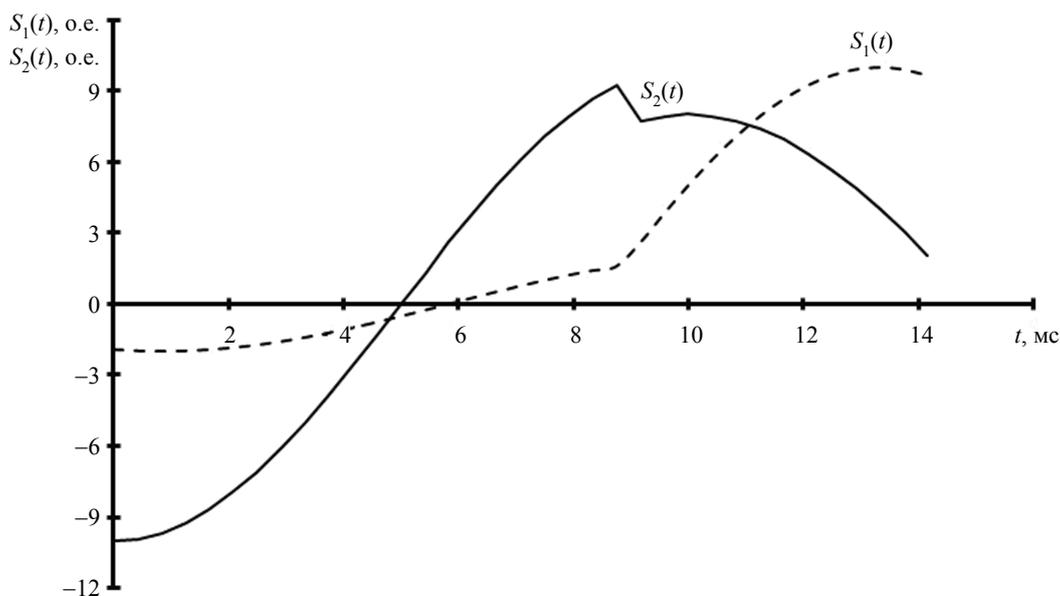


Рис. 4. Сигналы $S_1 = (t)$ (пунктирная линия) и $S_2 = (t)$ (сплошная линия) на входе ИНС после АЦП

Fig. 4. Signals $S_1 = (t)$ (dotted line) and $S_2 = (t)$ (solid line) at the ANN input after the ADC

Результат работы ИНС представлен на рисунке 5. Как видно из рисунка 5, ИНС за время, соответствующее интервалу дискретизации, определяет изменение значения $\Delta\phi$. При этом можно использовать дополнительную обработку сигнала с выхода ИНС, например, медианное сглаживание по трем точкам (сигнал C на рис. 5), что позволит сглаживать отдельные редкие максимальные ошибки работы ИНС и даст дополнительную максимальную задержку при данной частоте дискретизации всего 0,83 мс.

В классическом случае задачи определения разности фаз решаются с использованием фильтров Фурье. Сначала определяются значения фазы для каждого из сигналов, а затем вычисляется разность между ними. Точность фильтра Фурье в установившихся режимах работы энергосистемы, несомненно, выше. В то же время использование фильтра Фурье подразумевает предварительное вычисление частоты сети и подстройку окна наблюдения фильтра Фурье. При невыполнении данного условия в случае значительного отклонения частоты основного сигнала точность фильтра Фурье существенно снижается. ИНС сразу же обучается для работы с аналоговыми сигналами, частота которых может лежать в широком диапазоне – 45...55 Гц. При этом общее время реакции системы на базе нейронной сети будет не менее чем в 12 раз меньше, чем у фильтра Фурье.

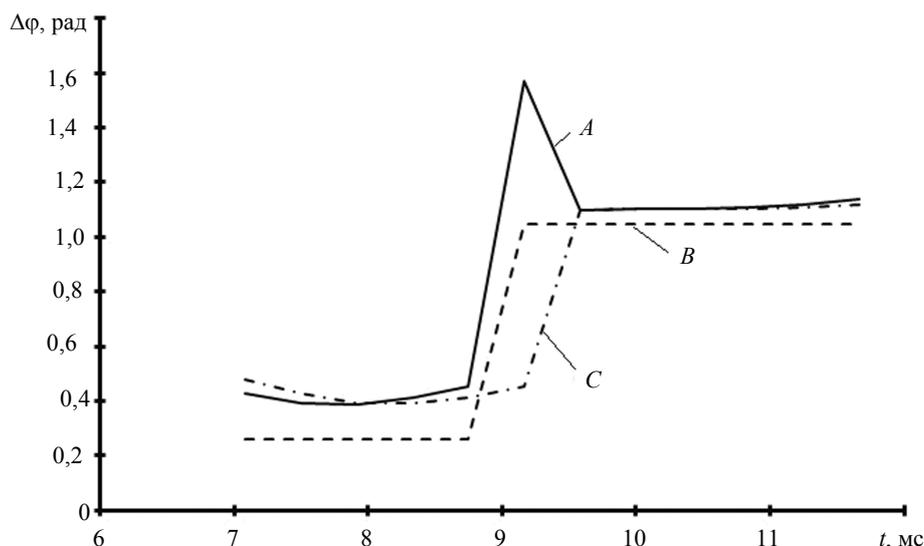


Рис. 5. Работа ИНС: A – значение $\Delta\varphi$ на выходе ИНС; B – значение $\Delta\varphi$ сигналов $S_1 = (t)$ и $S_2 = (t)$ на входе в ИНС; C – значение $\Delta\varphi$ с выхода ИНС после дополнительной обработки

Fig.5. The ANN work: A is the value of $\Delta\varphi$ at the ANN output, B is the value of $\Delta\varphi$ of the signals $S_1 = (t)$ and $S_2 = (t)$ at the ANN input, C is the value of $\Delta\varphi$ from the ANN output after additional processing

Обсуждение

Анализ и обработка сигналов широко применяются в контрольно-измерительной аппаратуре как во временном, так и в спектральном представлении [26], в частности при анализе временных изменений спектра сигналов [27]. Спектральный анализ сигналов на основе преобразования Фурье [28] обладает высоким быстродействием и точностью, однако требует определенной длительности временного окна. В электроэнергетической системе фильтры Фурье получили распространение благодаря простоте реализации и точности определения гармонических составляющих сигнала. Однако последнее справедливо для установившихся процессов. Для достижения высокой точности фильтру Фурье необходимо окно наблюдения кратное периоду сигнала промышленной частоты. При возникновении аварийного процесса в окно наблюдения фильтра Фурье помимо сигнала аварийного режима на некоторое время попадает сигнал предаварийного режима. Также необходимо учитывать, что при возникновении аварии сигналы меняют свое значение не мгновенно, а по мере развития аварийных процессов. Таким образом, значения фазы сигналов, определяемые фильтром Фурье в момент возникновения аварии, являются некими усредненными значениями за время не менее периода сигнала промышленной частоты. Данный факт замедляет, например, работу органа направления мощности (ОНМ). ОНМ используется при работе

встречно-направленной логической защиты шин (ЛЗШ) для шин с многосторонним питанием. В условиях с многосторонним питанием для обеспечения селективности используются направленные токовые защиты. ОНМ обеспечивает два управляющих воздействия: «вне зоны» – направление мощности направлено из зоны защищаемого объекта, «в зоне» – направление мощности направлено внутрь защищаемого объекта. Направление проходящей мощности аварийного тока характеризует место возникновения повреждения – на «своем» присоединении либо где-то еще. ЛЗШ в настоящее время входит в состав практически любого микропроцессорного устройства релейной защиты среднего напряжения. Задача ЛЗШ – отключить короткое замыкание на шинах распределительного устройства (РУ) за минимально возможное время. Применение нейронной сети для определения разности фаз между током и напряжением потенциально позволяет ускорить работу встречно направленной ЛЗШ.

Совместное использование фильтра Фурье и аппарата ИНС может позволить создавать гибридные измерительные органы устройств релейной защиты. На начальном этапе ИНС может работать в режиме наблюдателя, то есть просто «наблюдать» за аналоговыми сигналами и в случае возникновения аварийной ситуации выдавать информационные сигналы об изменении параметров сигналов. В дальнейшем, по мере накопления базы знаний и статистики ра-

боты, совершенствования методов обучения таких ИНС, можно подключать нейросети уже как полноценный элемент измерительного органа и использовать данные с выхода ИНС в случае детектирования аварийного процесса. При этом ИНС может быть использована в качестве детектора для определения начала аварийного процесса. В таком случае нейросеть сама может выдавать сигнал о наличии аварии, сигнализируя о том, что необходимо, в том числе, учитывать данные с выхода нейросети в алгоритмах работы ИЭУ.

Благодаря быстрдействию ИНС может быть применима и для задач определения мест повреждения [29]. Важным представляется следующий факт: наличие в сигналах шума в единицы процентов от его амплитуды не нарушает устойчивости работы и лишь незначительно увеличивает погрешности ИНС при ее адекватном обучении.

Выводы

Таким образом, ИНС может эффективно применяться для определения разности фаз $\Delta\varphi$ двух сигналов в ИЭУ во время переходных процессов, возникающих в энергосистеме в аварийных ситуациях. ИНС достаточно всего двух дискретизированных отсчетов каждого из аналоговых сигналов для выполнения этой задачи. Даже при использовании дополнительных способов обработки выходных сигналов ИНС для повышения точности определения $\Delta\varphi$ время реакции устройства на основе ИНС может быть в 6 раз меньше, чем у фильтра Фурье; минусом является точность вычислений ИНС в установившихся режимах, что позволяет совместно использовать оба алгоритма.

Оценка скорости вычислений параметров сигнала микропроцессорным устройством при использовании ИНС показала, что простая заранее обученная ИНС прямого распространения может использоваться в уже существующих микропроцессорных устройствах, в том числе на базе микроконтроллеров отечественного производства наравне с фильтрами Фурье в режиме реального времени.

Использование ИНС позволяет разрабатывать новые интеллектуальные гибридные измерительные органы устройств релейной защиты, реализованные в ИЭУ. Применение гибридных измерительных органов дает возможность уменьшить время на принятие решения микропроцессорных устройств релейной защиты при возникновении аварийных режимов в энергосистеме, что в целом позволит уменьшить последствия аварий.

Библиографические ссылки

1. Jaroslav Timko, Peter Girovský (2006) Nonlinear System Control Using Neural Networks. Acta Polytechnica Hungarica, 2006, vol. 3 (4), pp. 85-94.
2. Plett G.L. (2003) Adaptive inverse control of linear and nonlinear systems using dynamic neural networks: IEEE Trans Neural Netw, 2003, vol. 14 (2), pp. 360-376. DOI: 10.1109/TNN.2003.809412
3. Parlos A.G., Chong K.T., Atiya A.F. (1994) Application of the recurrent multilayer perceptron in modeling complex process dynamics: IEEE Trans Neural Netw, 1994, vol. 5 (2), pp. 255-266. DOI: 10.1109/72.279189
4. José A.R. Vargas, Pedrycz W., Hemerly M. Elder (2019) Improved learning algorithm for two-layer neural networks for identification of nonlinear systems. Neurocomputing, 2019, vol. 329, pp. 86-96. DOI: 10.1016/j.neucom.2018.10.008
5. Hornik Kurt, Stinchcombe Maxwell, White Halbert. (1990) Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. Neural Networks, 1990, vol. 3 (5), pp. 551-560. DOI: 10.1016/0893-6080(90)90005-6
6. Li Xiaouu, Yu Wen. (2002) Dynamic system identification via recurrent multilayer perceptrons. Information Sciences, 2002, vol. 147 (1-4), pp. 45-63. DOI: 10.1016/S0020-0255(02)00207-4
7. Eddahech A., Briat O., Vinassa J. (2011) Neural networks based model and voltage control for lithium polymer batteries: 8th IEEE Symposium on Diagnostics for Electrical Machines, Power Electronics & Drives: Bologna, Italy, 2011, pp. 645-650. DOI: 10.1109/DEMPED.2011.6063692
8. Ghlib I., Messlem Y., Chedjara Z. (2019) ADALINE-Based Speed Control For Induction Motor Drive: 2019 International Conference on Advanced Electrical Engineering (ICAEE). Algiers, Algeria, 2019, pp. 1-6. DOI: 10.1109/ICAEE47123.2019.9015162
9. Buettner M. A., Monzen N., Hackl C. M. (2022) Artificial Neural Network Based Optimal Feedforward Torque Control of Interior Permanent Magnet Synchronous Machines: A Feasibility Study and Comparison with the State-of-the-Art. Energies, 2022, vol. 15 (5), p. 1838. DOI: 10.3390/en15051838
10. Alhanjouri Mohammed (2017) Speed Control of DC Motor using Artificial Neural Network. International Journal of Science and Research (IJSR), 2017, vol. 7, pp. 2140-2148. DOI: 10.21275/ART20172035
11. Brdyś M.A., Kulawski G.J. (1999) Dynamic neural controllers for induction motor. IEEE Trans Neural Netw, 1999, vol. 10 (2), pp. 340-55. DOI: 10.1109/72.750564
12. Dillon T.S., Niebur D. (1996) Neural Networks Application in Power Systems. CRL Ltd. Publishing, London, 1996.
13. Osowski S. (1992) Neural network for estimation of harmonic components in a power system: IEEE Proceedings on Generation, Transmission and Distribution, 1992, vol. 139 (2), pp. 129-135.
14. Панов М., Хмелев И., Смирнов А. Нейронные сети на службе энергетиков // Открытые системы. СУБД. 2016. № 4. С. 39–41. ISSN 1028-7493

15. Куликов А. Л., Лоскутов А. А., Бездушный Д. И. Алгоритмы релейной защиты и автоматики электрических сетей, основанные на имитационном моделировании и методах машинного обучения // Стратегия устойчивого развития электроэнергетики, низкоуглеродные способы генерации, экология, тарифное регулирование. М. : Изд-во МЭИ, 2022. С. 101–129.

16. Лоскутов А. А., Митрович М., Осокин В. Ю. Повышение распознаваемости режимов функционирования системы электроснабжения на основе методов машинного обучения // Релейная защита и автоматизация. 2020. № 4 (41). С. 26–34.

17. Симонов Н., Ивнев Н. Опыт и перспективы применения искусственных нейронных сетей в электроэнергетике // Электроэнергия. Передача и распределение. 2019. № S4 (15). С. 42–48.

18. Курбацкий В. Г., Томин Н. В. Применение новых информационных технологий в решении электроэнергетических задач // Системы. Методы. Технологии. 2009. № 1 (1). С. 113–119.

19. Haque M.T., Atabak M.K. (2007) Application of Neural Networks in Power Systems; A Review. International Journal of Energy and Power Engineering, 2007: 1: 897-901.

20. Shah1 B.S., Parmar S.B. (2017) Transformer protection using artificial neural network. IJNRD, 2017, vol. 2 (5), pp. 108-111.

21. Андреев О. Н., Славутский А. Л., Алексеев В. В. Структурный анализ электротехнических сигналов при рекуррентном использовании многослойного перцептрона // Электротехника. 2022. № 8. С. 41–44. DOI: 10.53891/00135860_2022_8_41

22. Andreev O.N., Slavutskiy A.L., Slavutskiy L.A. Neural network in a sliding window for power grids signals structural analysis. IOP Conference Series: Earth and Environmental Science, 990 012054. <https://iopscience.iop.org/article/10.1088/1755-1315/990/1/012054>

23. Rukonuzzman M. and Nakaoka M. (2002) An Advanced Three-Phase Active Filter with Adaptive Neural Network Based Harmonic Detection Scheme. Journal of Power Electronics, 2002, vol. 2, no. 1, pp. 1-10. DOI: 10.6113/JPE.2001.02.1.1

24. Slavutskiy L.A., Lazareva N.M., Portnov M.S., Slavutskaya E.V. (2023) Neural net without deep learning: signal approximation by multilayer perceptron: 2nd International Conference on Computer Applications for Management and Sustainable Development of Production and Industry (CMSD-II-2022), Proc. SPIE, 2023, p. 125640. DOI: 10.1117/12.2669233

25. Хайкин С. Нейронные сети: полный курс : пер. с англ. 2-е изд. М. : ООО «И.Д. Вильямс», 2006. – 1104 с.

26. Муравьева О. В., Брестер А. Ф., Муравьев В. В. Сравнительная чувствительность информативных параметров электромагнитно-акустического зеркально-теневоего метода на многократных отражениях при контроле пруткового проката // Дефектоскопия. 2022. № 8. С. 36–51. DOI: 10.31857/S0130308222080048

27. Ядарова О. Н., Славутский Л. А. Контроль воздушного потока на основе доплеровского рассея-

ния ультразвука // Приборы и системы. Управление, контроль, диагностика. 2013. № 3. С. 55–59.

28. Пономарева О. В., Пономарев А. В., Смирнова Н. В. Алгоритмы прямого и обратного параметрического быстрого преобразования Фурье // Информационные технологии. 2022. Т. 28, № 1. С. 9–19. DOI: 10.17587/it.28.9-19

29. Slavutskiy L.A., Ivanova N.N. (2020) Using the simplest neural network as a tool for fault location in power lines: AIP Conference Proceedings, Moscow, 2020, 01-02 April, p. 030006. DOI: 10.1063/5.007492

References

1. Jaroslav Timko, Peter Girovský (2006) Nonlinear System Control Using Neural Networks. Acta Polytechnica Hungarica, 2006, vol. 3 (4), pp. 85-94.

2. Plett G.L. (2003) Adaptive inverse control of linear and nonlinear systems using dynamic neural networks: IEEE Trans Neural Netw, 2003, vol. 14 (2), pp. 360-376. DOI: 10.1109/TNN.2003.809412

3. Parlos A.G., Chong K.T., Atiya A.F. (1994) Application of the recurrent multilayer perceptron in modeling complex process dynamics: IEEE Trans Neural Netw, 1994, vol. 5 (2), pp. 255-266. DOI: 10.1109/72.279189

4. José A.R. Vargas, Pedrycz W., Hemery M. (2019) Elder. Improved learning algorithm for two-layer neural networks for identification of nonlinear systems. Neurocomputing, 2019, vol. 329, pp. 86-96. DOI: 10.1016/j.neucom.2018.10.008

5. Hornik Kurt, Stinchcombe Maxwell, White Halbert (1990) Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. Neural Networks, 1990, vol. 3 (5), pp. 551-560. DOI: 10.1016/0893-6080(90)90005-6

6. Li Xiaou, Yu Wen (2002) Dynamic system identification via recurrent multilayer perceptrons. Information Sciences, 2002, vol. 147 (1-4), pp. 45-63. DOI: 10.1016/S0020-0255(02)00207-4

7. Eddahech A. Briat O., Vinassa J. (2011) Neural networks based model and voltage control for lithium polymer batteries: 8th IEEE Symposium on Diagnostics for Electrical Machines, Power Electronics & Drives: Bologna, Italy, 2011, pp. 645-650. DOI: 10.1109/DEMPED.2011.6063692

8. Ghlib I., Messlem Y., Chedjara Z. (2019) ADALINE-Based Speed Control For Induction Motor Drive: 2019 International Conference on Advanced Electrical Engineering (ICAEE). Algiers, Algeria, 2019, pp. 1-6. DOI: 10.1109/ICAEE47123.2019.9015162

9. Buettner M.A., Monzen N., Hackl C.M. (2022) Artificial Neural Network Based Optimal Feedforward Torque Control of Interior Permanent Magnet Synchronous Machines: A Feasibility Study and Comparison with the State-of-the-Art. Energies, 2022, vol. 15 (5), p. 1838. DOI: 10.3390/en15051838

10. Alhanjouri Mohammed (2017) Speed Control of DC Motor using Artificial Neural Network. International Journal of Science and Research (IJSR), 2017, vol. 7, pp. 2140-2148. DOI: 10.21275/ART20172035

11. Brdyś M.A., Kulawski G.J. (1999) Dynamic neural controllers for induction motor. *IEEE Trans Neural Netw*, 1999, vol. 10 (2), pp. 340-55. DOI: 10.1109/72.750564
12. Dillon T.S., Niebur D. (1996) *Neural Networks Application in Power Systems*. CRL Ltd. Publishing, London, 1996.
13. Osowski S. (1992) Neural network for estimation of harmonic components in a power system: *IEEE Proceedings on Generation, Transmission and Distribution*, 1992, vol. 139 (2), pp. 129-135.
14. Panov M., Khmelev I., Smirnov A. [Neural networks in the service of power engineers]. *Otkrytye sistemy SUBD*, 2016, no. 4, pp. 39-41 (in Russ.). ISSN 1028-7493
15. Kulikov A.L., Loskutov A.A., Bezdushnyi D.I. *Algoritmy releinoi zashchity i avtomatiki elektricheskikh setei, osnovannye na imitatsionnom modelirovanii i metodakh mashinnogo obucheniya* [Algorithms of relay protection and automation of electrical networks based on simulation modeling and machine learning methods]. *Strategiya ustoychivogo razvitiya elektroenergetiki, nizkouglerodnye sposoby generatsii, ekologiya, tarifnoe regulirovanie* [Strategy of sustainable development of the electric power industry, low-carbon generation methods, ecology, tariff regulation]. Moscow: MPEI Publ. House, 2022, pp. 101-129 (in Russ.).
16. Loskutov A.A., Mitrovich M., Osokin V.Yu. [Increasing the recognizability of the modes of operation of the power supply system based on machine learning methods]. *Releynaya zashchita i avtomatizatsiya*, 2020, no. 4 (41), pp. 26-34 (in Russ.).
17. Simonov N., Ivenev N. [Experience and prospects for the use of artificial neural networks in the electric power industry]. *Elektroenergiya. Peredacha i raspredelenie*, 2019, no. S4 (15), pp. 42-48 (in Russ.).
18. Kurbatskii V.G., Tomin N.V. [Application of new information technologies in solving electric power problems]. *Sistemy. Metody. Tekhnologii*, 2009, no. 1 (1), pp. 113-119 (in Russ.).
19. Haque M.T., Atabak M.K. (2017) Application of Neural Networks in Power Systems; A Review. *International Journal of Energy and Power Engineering*, 2007: 1: 897-901.
20. Shah1 B.S., Parmar S.B. (2017) Transformer protection using artificial neural network. *IJNRD*, 2017, vol. 2 (5), pp. 108-111.
21. Andreev O.N., Slavutskiy A.L., Alekseev V.V. [Structural Analysis of Electrical Signals with Recurrent Use of a Multilayer Perceptron]. *Elektrotekhnika*, 2022, no. 8, pp. 41-44 (in Russ.). DOI: 10.53891/00135860_2022_8_41
22. Andreev O.N., Slavutskiy A.L., Slavutskiy L.A. Neural network in a sliding window for power grids signals structural analysis. *IOP Conference Series: Earth and Environmental Science*, 990 012054. <https://iopscience.iop.org/article/10.1088/1755-1315/990/1/012054>
23. Rukonuzzman M. and Nakaoka M. (2002) An Advanced Three-Phase Active Filter with Adaptive Neural Network Based Harmonic Detection Scheme. *Journal of Power Electronics*, 2002, vol. 2, no. 1, pp. 1-10. DOI: 10.6113/JPE.2001.02.1.1
24. Slavutskiy L.A., Lazareva N.M., Portnov M.S., Slavutskaya E.V. (2023) Neural net without deep learning: signal approximation by multilayer perceptron: 2nd International Conference on Computer Applications for Management and Sustainable Development of Production and Industry (CMSD-II-2022), *Proc. SPIE*, 2023, p. 125640. DOI: 10.1117/12.2669233
25. Haykin S. *Neironnye seti: polnyi kurs* [Neural Networks: A Comprehensive Foundation]. Moscow, OOO "I.D. Williams", 2006, 1104 p. (in Russ.).
26. Murav'eva O.V., Brester A.F., Murav'ev V.V. [Comparative Sensitivity of Informative Parameters of the Electromagnetic-Acoustic Mirror-Shadow Method on Multiple Reflections in the Control of Bars]. *Defektoskopiya*, 2022, no. 8, pp. 36-51 (in Russ.). DOI: 10.31857/S0130308222080048
27. Yadarova O.N., Slavutskiy L.A. [Airflow control based on Doppler ultrasound scattering]. *Pribory i sistemy. Upravlenie, kontrol', diagnostika*, 2013, no. 3, pp. 55-59 (in Russ.).
28. Ponomareva O.V., Ponomarev A.V., Smirnova N.V. [Algorithms for direct and inverse parametric fast Fourier transform]. *Informatsionnye tekhnologii*, 2022, vol. 28, no. 1, pp. 9-19 (in Russ.). DOI: 10.17587/it.28.9-19
29. Slavutskiy L.A., Ivanova N.N. (2020) Using the simplest neural network as a tool for fault location in power lines: *AIP Conference Proceedings*, Moscow, 2020, 01-02 April, p. 030006. DOI: 10.1063/5.007492

Neural Network Hardware and Software Real Time Control of Electrical Signals Phase Shift

O.N. Andreev, Postgraduate, Chuvash State University, Cheboksary, Russia

A.L. Slavutskiy, PhD in Engineering, LLC "Unitel Engineering", Cheboksary, Russia

Artificial neural networks are increasingly being used in the intelligent electric power industry. Smart grids are the key components of digital economy. The work purpose is to show the possibility of using a simple architecture neural network in the appropriate microprocessor engineering for improvement such microprocessor device characteristics as reducing the device reaction time, increasing the decision-making accuracy in the accident and the ability to more accurate localization of the accident site. This reduces the negative accident consequences, time of determination of the accident location and, accordingly, the time to eliminate the accident consequences, and to restore the normal power system operation. Neural network training is a long-lasting process. At the same time, neural network "deep learning" does not guarantee their default-free operation. So, it is proposed to introduce a pre-trained neural network into intelligent electronic devices when electrical signals can be described by analytical formulas and the

possible variation ranges of such signal parameters are set in advance. The corresponding approach has been implemented and tested in a microprocessor device for signal phase shift in transient mode rapid estimation. It is shown that the phase difference estimation can be carried out in a time not exceeding 1 ms., which significantly exceeds conventional algorithms based on the Fourier filter capabilities. The practical application and joint use of the Fourier filter and the artificial neural network possibilities for the creation relay protection device hybrid measuring elements are discussed. The approach and the obtained results can potentially be applied in a wide range of signal processing tasks.

Keywords: artificial neural network, microcontroller, microprocessor, signal processing, emergency modes, relay protection.

Получено 22.02.2023

Образец цитирования

Андреев О. Н., Славутский А. Л. Нейросетевой программно-аппаратный контроль сдвига фаз электрических сигналов в реальном времени // Вестник ИжГТУ имени М. Т. Калашникова. 2023. Т. 26, № 2. С. 76–84. DOI: 10.22213/2413-1172-2023-2-76-84.

For Citation

Andreev O.N., Slavutskiy A.L. Neural Network Hardware and Software Real Time Control of Electrical Signals Phase Shift. *Vestnik IzhGTU imeni M.T. Kalashnikova*, 2023, vol. 26, no. 2, pp. 76-84 (in Russ.). DOI: 10.22213/2413-1172-2023-2-76-84.