

Marta KOLASA*
Rafał DŁUGOSZ*

KONCEPCJA ZASTOSOWANIA SZTUCZNYCH SIECI NEURONOWYCH DO LOKALIZACJI ELEMENTÓW POWODUJĄCYCH POGORSZENIE JAKOŚCI ENERGII ELEKTRYCZNEJ W SIECIACH ŚREDNIEGO NAPIĘCIA

W artykule przedstawiono koncepcję wykorzystania sztucznych sieci neuronowych do rozwiązywania problemu lokalizacji źródeł zakłóceń powodujących pogorszenie jakości energii elektrycznej. W dziedzinie tej coraz częściej sięga się po rozwiązania oparte na sztucznej inteligencji, choć zazwyczaj stosowane algorytmy uczenia sieci neuronowych implementowane są jako programy komputerowe. Biorąc pod uwagę ogromną ilość danych, które muszą zostać przetworzone, rozwiązania takie nie są optymalne. Rozwiązaniem tego problemu może być zastosowanie równoległego przetwarzania danych, możliwego do uzyskania w sieciach neuronowych realizowanych jako specjalizowane układy scalone. Jest to celem naszych badań. W artykule przedstawiono jeden z etapów realizacji tego zadania – model sieci elektroenergetycznej, którego celem jest dostarczenie danych uczących dla projektowanej na poziomie tranzystorów sieci neuronowej. W realizowanej sieci neuronowej wykorzystano nowatorski algorytm oparty na filtracji błędu kwantyzacji, który pozwala znacząco skrócić fazę uczenia, przez co sieć jest w stanie szybko dostosować się do nowych danych.

SŁOWA KLUCZOWE: jakość energii elektrycznej, sztuczne sieci neuronowe, nowe algorytmy uczenia

1. WSTĘP

W ostatnich latach widoczny jest znaczący wzrost zainteresowania tematyką jakości energii elektrycznej [1, 6, 7, 11, 12, 13, 15]. Jednym z głównych problemów w sieciach elektroenergetycznych są pojawiające się wyższe harmoniczne, które powodują np. odkształcenia przebiegów napięć, błędy w pracy przyrządów pomiarowych, nieprawidłową pracę sprzętu zabezpieczającego, wzrost strat mocy, itp. [12]. Energia elektryczna przestała być postrzegana wyłącznie w kategoriach ilościowych jako wielkość fizyczna, lecz zaczęła podlegać restrykcyjnej ocenie oraz standaryzacji. Jakość energii elektrycznej określa jej przydatność do zasilania odbiorników energii elektrycznej [7]. O własnościach użytkowych energii decyduje nie tylko wytwórca, lecz przede wszystkim odbiorcy energii oraz jej dystrybutor, a także

* Uniwersytet Technologiczno-Przyrodniczy w Bydgoszczy.

producent urządzeń eksploatowanych u odbiorców. Kluczowym problemem w tej branży jest to, że energia podlega degradacji w procesie jej przesyłu oraz dystrybucji pod wpływem występujących zaburzeń elektromagnetycznych. Głównym źródłem tych zaburzeń są różne odbiorniki nieliniowe, których liczba nieustannie rośnie. Z tego względu, w przypadku znaczącego odkształcenia napięcia w sieci zasilającej, występuje potrzeba zlokalizowania rodzaju zaburzenia oraz jego źródła. Ma to szczególne znaczenie zwłaszcza w okresie formułowania kontraktów na dostawę energii i egzekwowania opłat za pogarszanie jakości zasilania. Harmoniczne prądu przenoszone są przez sieć. W związku z tym odbiorcy energii, którzy sami nie przyczyniają się do ich powstawania w sieci mogą być narażeni na ich oddziaływanie. W wielu przypadkach wymagane jest określenie ilościowego udziału dostawcy oraz odbiorcy energii w całkowitym odkształceniu napięcia w punkcie wspólnego przyłączenia [7].

Problem lokalizacji źródeł wyższych harmonicznych w systemie elektroenergetycznym jest szeroko poruszany w literaturze [1, 2, 7, 11-15]. Wiele z obecnie stosowanych metod lokalizacji źródeł składowych harmonicznych opiera się na badaniu kierunku przepływu mocy czynnej dla poszczególnych składowych. Wielu autorów zwraca jednak uwagę na ograniczenia tych metod [1, 7, 13]. "Metoda impedancyjna", w przeciwieństwie do metody przepływu mocy czynnej, pozwala na dokonanie oceny udziału dostawcy i odbiorcy energii w całkowitym odkształceniu napięcia i jest uznawana za najbardziej miarodajną ze wszystkich sposobów lokalizacji źródeł wyższych harmonicznych [7, 15]. Jednakże większość metod proponowanych w literaturze: "metoda impedancyjna" [15], badanie kierunku przepływu mocy biernej oraz „impedancji krytycznej” [15], iniekcja interharmonicznych [14] itp., oprócz złożoności technicznej realizacji wymagają posiadania dokładnych informacji o wartościach parametrów zastępczych analizowanego systemu [1]. Są to dane trudno dostępne lub też uzyskiwane poprzez kosztowne pomiary.

Alternatywą w rozwiązywaniu opisywanych problemów jest zastosowanie metod oceny wpływu pracy odbiorników nieliniowych na jakość energii elektrycznej opartych na systemach sztucznej inteligencji. Zaletą rozwiązań tego typu jest umiejętność radzenia sobie z okresowym brakiem pewnych danych, co często się zdarza. Zastosowanie sztucznych sieci neuronowych oraz innych systemów opartych na sztucznej inteligencji w elektroenergetyce zyskuje na popularności [6, 7, 11]. Wykorzystywane są one w zagadnieniach związanych z prognozowaniem przyszłych wartości energii elektrycznej, detekcją uszkodzeń elementów systemu elektroenergetycznego czy też jakością energii elektrycznej [6, 7, 11].

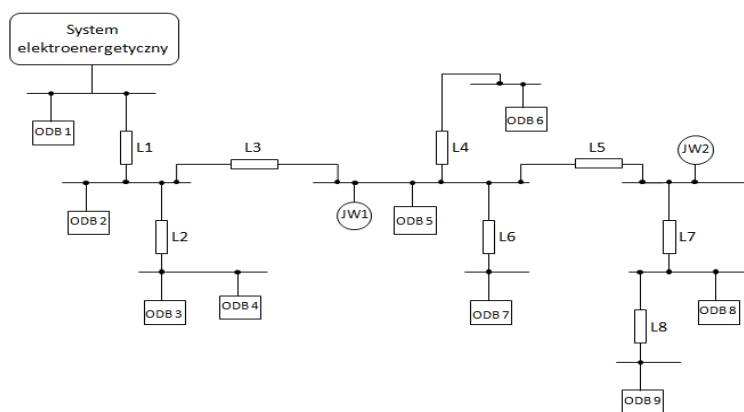
Jednym z celów autorów pracy jest zrealizowanie nowatorskiego systemu diagnostycznego, który pozwoli na monitorowanie zawartości wyższych harmonicznych w systemie elektroenergetycznym w trybie ciągłym. W artykule przedstawiono koncepcję systemu (inteligentnego klasyfikatora), opartego na sztucznej sieci neuronowej, koncentrując się przede wszystkim na zaimplementowanym w nim algorytmie uczenia, który jest dedykowany zarówno

do rozwiązań sprzętowych jak i softwarowych [10]. W zaproponowanym algorytmie wykorzystano filtrację cyfrową, która pozwala na znaczące skrócenie czasu uczenia sieci. Ma to znaczenie z punktu widzenia konieczności szybkiego dostosowywania się sieci neuronowej do zmieniających się warunków, w jakich pracuje sieć neuronowa.

Jednym z podstawowych problemów przy zastosowaniu sieci neuronowych w systemach oceny jakości energii jest właściwie zdefiniowane danych uczących dla takiej sieci [7]. Dane te muszą z jednej strony dobrze opisywać problem, tak by sieć mogła wskazywać właściwie źródła zakłóceń. Z drugiej strony struktura tych danych musi być na tyle prosta by sieć mogła je właściwie przetworzyć. Aby dostarczyć danych uczących autorzy zaprojektowali model systemu elektroenergetycznego w środowisku Matlab Simulink. Szczegóły dotyczące modelu zaprezentowano w rozdziale 2. W kolejnym rozdziale autorzy przedstawili koncepcję szybkiego uczenia samoorganizujących się sieci neuronowych. Wnioski przedstawiono w rozdziale ostatnim.

2. CHARAKTERYSTYKA PRZYKŁADOWEJ SIECI ELEKTROENERGETYCZNEJ ŚREDNIEGO NAPIĘCIA - MODEL

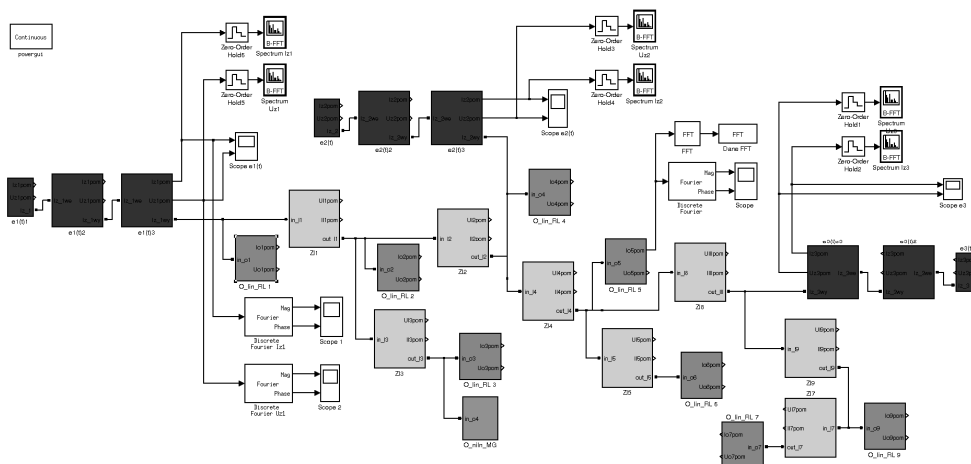
Aby dostarczyć dane uczące dla opracowywanej sieci neuronowej zastosowano przykładową elektroenergetyczną sieć dystrybucyjną, której schemat zastępczy pokazano na rys. 1.



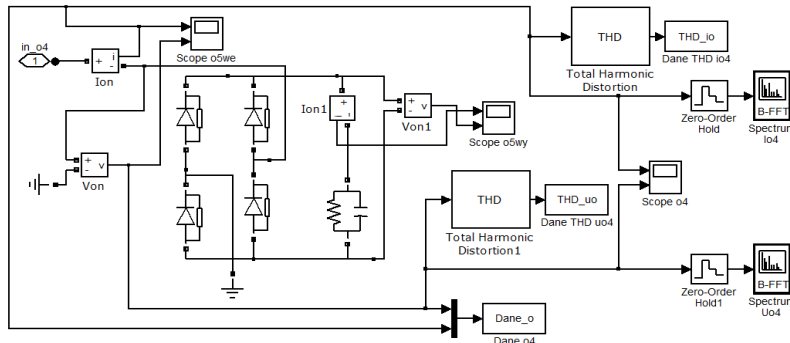
Rys. 1. Schemat zastępczy przykładowej sieci dystrybucyjnej

Sieć elektroenergetyczna składa się z następujących elementów: generatora zastępczego (system elektroenergetyczny – zastąpiony idealnym źródłem napięcia połączonym szeregowo z rezystorem i cewką), dwóch jednostek wytwórczych JW1 i JW2 (uwzględnienie generacji rozproszonej), dziewięciu odbiorów ODB1 – 9

oraz ośmiu odcinków linii elektroenergetycznych L1 – 8 średniego napięcia. Sposób wyznaczania parametrów poszczególnych elementów schematu zastępczego został szczegółowo opisany w pracach [3, 4].



Rys. 2. Konstrukcja blokowa modelu w środowisku Matlab Simulink

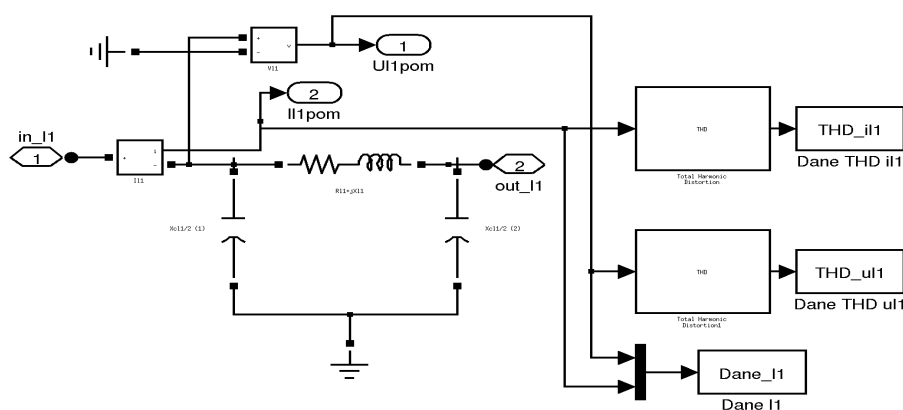


Rys. 3. Schemat struktury wewnętrznej bloku „odbior nieliniowy” w środowisku Matlab Simulink

Na potrzeby testowania sieci neuronowej opracowano model elektroenergetycznej sieci średniego napięcia (rys. 1) w środowisku Matlab Simulink, z wykorzystaniem języka programowania wysokiego poziomu. Na rys. 2. przedstawiono konstrukcję blokową modelu. Model umożliwia symulacyjne prowadzenie badań stopnia odkształceń napięć oraz prądów w poszczególnych węzłach oraz gałęziach przykładowej sieci elektroenergetycznej oraz w odbiorach. Model zawiera źródła napięcia umożliwiające pracę w dwóch trybach, tj. generujące napięcie sinusoidalne oraz napięcie odkształcone (z możliwością zadawania wartości amplitud i faz poszczególnych harmonicznych).

W razie konieczności wprowadzenia impedancji wewnętrznej źródła napięcia (rzeczywiste źródło napięcia), dołącza się szeregowo połączone rezystory i cewki. W węzłach sieci elektroenergetycznej możliwe jest przyłączenie liniowych bądź nieliniowych odbiorów (rys. 3). Nieliniowe odbiory są kolejnym elementem wpływającym na pogorszenie kształtu krzywej napięć i prądów w rozpatrywanej sieci elektroenergetycznej. Schemat struktury wewnętrznej bloku oznaczonego jako „linia elektroenergetyczna” (rys. 4) opracowano zgodnie z klasycznymi schematami zastępczymi linii elektroenergetycznych [16, 17].

Model uzupełniono miernikami zawartości wyższych harmonicznych wybranych prądów oraz napięć sieci. Zaimplementowany model pozwala na badanie wpływu dołączenia poszczególnych odbiorów lub zwiększenia zawartości harmonicznych w napięciach źródłowych na jakość energii elektrycznej, w szczególności na odkształcenie krzywych prądów i napięć w różnych miejscach rozpatrywanej, przykładowej sieci elektroenergetycznej. Model pozwala na uzyskanie niezbędnych danych służących do przeprowadzenia procesu uczenia, weryfikacji oraz testowania neuronowego klasyfikatora danych.



Rys. 4. Schemat struktury wewnętrznej bloku „linia elektroenergetyczna” w środowisku Simulink

3. OPIS SIECI NEURONOWEJ

Z uwagi na bardzo dużą liczbę węzłów systemu elektroenergetycznego oraz nieustannie rosnącą liczbę odbiorników, w tym odbiorników nieliniowych, system diagnozujący musi posiadać dużą mocą obliczeniową. Problem polega na tym, że współczesne realizacje sieci neuronowych oparte są głównie na platformach softwarowych, które nie pozwalają uzyskać dużych mocy obliczeniowych. Wynika to z szeregowego przetwarzania danych w tego typu systemach oraz często z niewystarczających zasobów sprzętowych. Aby zbudować system który zapewni odpowiednią moc obliczeniową, zachowując przy tym niewielkie wymiary, niezbędne jest zastosowanie systemów pozwalających na pracę równoległą [5, 9].

Proste zastosowanie systemów służących do równoległego przetwarzania sygnałów (np. układy FPGA – Field Programmable Gate Array) może okazać się niewystarczające. Wynika to z ograniczonych zasobów sprzętowych w tego typu urządzeniach. Konieczny jest również rozwój odpowiednich algorytmów uczenia sieci, które z jednej strony pozwolą na szybkie uczenie (duża zbieżność algorytmu uczenia), a z drugiej będą realizowalne na sprzętowych platformach równoległych.

Przykładem sieci neuronowych które mogą zostać w prosty sposób zastosowane w tym przypadku, głównie ze względu na prostotę algorytmów uczących, są samoorganizujące się sieci Kohonena [5, 9], zwane też samoorganizującymi mapami cech (*SOFM od ang. Self-Organized Feature Maps*). Składają się one z jednej warstwy neuronów, które tworzą mapę z liczbą wyjść równą liczbie neuronów. Wszystkie neurony w sieci mają wspólne wejścia. Zaletą sieci typu SOFM jest możliwość rzutowania wielowymiarowych danych wejściowych na przestrzeń o mniejszej liczbie wymiarów, zwykle dwuwymiarową, co przyczynia się do ich lepszej wizualizacji oraz analizy [8].

Konkurencyjne uczenie w sieciach SOFM polega na prezentowaniu sieci wektorów uczących X , w wyniku czego wagi poszczególnych neuronów adaptują się w taki sposób, że neurony te stają się reprezentantami poszczególnych klas sygnałów wejściowych. W sieciach tych dla każdego wzorca uczącego X najpierw określana jest odległość pomiędzy wzorcem X oraz wektorami wag W poszczególnych neuronów. W tym celu stosuje się różne miary odległości. Do najbardziej popularnych należą tzw. miara Manhattan oraz miara Euklidesa.

Konkurencję wygrywa ten neuron, którego wektor wag W jest najbardziej podobny do wektora uczącego X . W kolejnym kroku algorytmu następuje adaptacja wag neuronu zwycięskiego oraz dodatkowo tych neuronów, które należą do jego sąsiedztwa. Adaptacja odbywa się zgodnie z poniższą zależnością:

$$W_j(l+1) = W_j(l) + \eta_k(l)G(R, d(i, j))[X(l) - W_j(l)] \quad (1)$$

gdzie η_k jest współczynnikiem uczenia w k -tej epoce uczącej, W_j jest wektorem wag danego j -tego neuronu, X jest wzorcem uczącym w l -tej prezentacji, $d(i, j)$ jest odległością topologiczną pomiędzy poszczególnymi neuronami na mapie, $G()$ jest zadaną funkcją sąsiedztwa, natomiast R zasięgiem sąsiedztwa.

Efektywność procesu uczenia samoorganizującej się sieci neuronowej oceniana jest za pomocą różnych kryteriów. Jednym z nich jest błąd kwantyzacji, który dla m n -wymiarowych wzorców w wejściowym zbiorze danych definiowany jest następująco:

$$Qerr = \frac{1}{m} \sum_{j=1}^m \sqrt{\sum_{l=1}^n (x_{j,l} - w_{i,l})^2} \quad (2)$$

4. PROPONOWANY ALGORYTM UCZENIA SIECI NEURONOWEJ

Jednym z celów badań jest opracowanie szybkozbieżnych algorytmów uczenia sieci neuronowych, które dzięki temu będą w stanie w krótkim czasie lokalizować źródła odkształceń napięcia w sieci elektroenergetycznej. Proponowany system oparty będzie na nowatorskim wykorzystaniu filtrów cyfrowych o skończonej odpowiedzi impulsowej oraz nieliniowych filtrów medianowych.

Dotychczasowe badania pokazują, że w trakcie uczenia sieci błąd kwantyzacji (2) nie maleje jednostajnie, ale widoczne są fazy stagnacji oraz gwałtownego zmniejszania wartości tego błędu (fazy aktywności). Te drugie fazy pojawiają się zawsze po przełączeniu promienia sąsiedztwa, R (1). W fazach stagnacji nie jest widoczny postęp w uczeniu sieci. Proponowany algorytm poprzez odpowiednią filtrację tego błędu jest w stanie wykryć fazy stagnacji i skracać je poprzez automatyczne przełączenie promienia R . Pozwala to skrócić czas procesu uczenia nawet o 70 – 90%. Nowy algorytm wraz z wynikami badań przeprowadzonymi na modelu softwarowym sieci został przedstawiony w szczegółach w [10].

5. PODSUMOWANIE

W artykule przedstawiono koncepcję zastosowania samoorganizujących sieci neuronowych w rozwiązywaniu problemów związanych z jakością energii. Na obecnym etapie badań gotowy jest model sieci elektroenergetycznej, który dostarczy danych uczących dla projektowanej sieci neuronowej. Trwają obecnie prace nad nowym algorytmem uczenia, który pozwoli znacząco zmniejszyć czas uczenia sieci. Gotowa jest też koncepcja sprzętowej realizacji takiej sieci, która pozwoli na zastosowanie równoległego przetwarzania danych, czyli znaczące zwiększenie mocy obliczeniowej układu. Sieć zostanie zrealizowana jako specjalizowany układ scalony w technologii CMOS.

LITERATURA

- [1] Bigaj D., Hanzelka Z., Metody lokalizacji źródeł wyższych harmonicznych w sieciach zasilających, Polskie Partnerstwo Jakości Zasilania, 2004.
- [2] Cieślik S., Problemy identyfikacji elementów systemu elektroenergetycznego powodujących wzrost wyższych harmonicznych napięcia. Miesięcznik Stowarzyszenia Elektryków Polskich INPE, Nr 152 (Rok XVIII), maj 2012r., str. 43-49.
- [3] Cieślik S., Przyłączenie farmy wiatrowej o mocy znamionowej 8 MW do szyn rozdzielni SN w stacji elektroenergetycznej WN/SN zasilającej elektroenergetyczną sieć dystrybucyjną. Przegląd Elektrotechniczny, 86, nr 6/2010, str. 104-109.
- [4] Cieślik S., Modelowanie matematyczne i symulacja układów elektroenergetycznych z generatorami indukcyjnymi. Wydawnictwa Uczelniane Uniwersytetu Technologiczno-Przyrodniczego, Bydgoszcz 2008.

- [5] Długosz R., Kolasa M., Pedrycz W., Szulc M., Parallel Programmable Asynchronous Neighborhood Mechanism for Kohonen SOM Implemented in CMOS Technology, *IEEE Transactions on Neural Networks*, Vol. 22, No. 12, 2011, str. 2091-2104.
- [6] Gała M., Zastosowanie sztucznych sieci neuronowych do oceny wpływu pracy odbiorników nieliniowych na jakość energii elektrycznej, *Przegląd Elektrotechniczny*, Nr 6/2011, str. 42-46.
- [7] Gała M., Analiza wpływu pracy odbiorników nieliniowych na zmiany wartości wybranych parametrów jakości energii elektrycznej z zastosowaniem sztucznych sieci neuronowych (rozprawa doktorska), Politechnika Częstochowska, 2007.
- [8] Kohonen T., *Self-Organizing Maps*, third ed. Springer, Berlin, 2001.
- [9] Kolasa M., Długosz R., Pedrycz W., Szulc M., A programmable triangular neighborhood function for a Kohonen self-organizing map implemented on chip, *Neural Networks*, Vol. 25, 2012, str. 146-160.
- [10] Kolasa M., Długosz R., Talaśka T., Pedrycz W., A fast learning algorithm based on filtering of the quantization error suitable for hardware implemented self-organizing maps, *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN)*, Brugia, Belgia, 23-25 kwietnia 2014.
- [11] azumdar J., Harley R.G., Lambert F.C., Venayagamoorthy G.K., Neural Network Based Method for Predicting Nonlinear Load Harmonics, *IEEE Transactions on Power Electronics*, vol. 22, no. 3, 2007, 1036-1045.
- [12] Pyzalski T., Wilkosz K., Identification of Harmonic Sources in a Power System: A New Method, *IEEE Russia Power Tech*, 2005, str. 1-6.
- [13] Szczęsny P., Wilczak P., Wybrane Metody Lokalizacji Źródeł Wyższych Harmonicznych w sieciach elektroenergetycznych, *Elektrotechnika i Elektronika*, Tom 28, Zeszyt 1-2, 2009, str. 39-48.
- [14] Tsukamoto M., Kouda I., Minowa Y., Nishimura S., Advanced Method to Identify Harmonics Characteristic Between Utility Grid and Harmonic Current Sources, *International Conference on Harmonics and Quality of Power*, 1998.
- [15] Xu Wilsun, Liu Xian, Liu Yilu, An Investigation on the Validity of Power-Direction Method for Harmonic Source Determination, *IEEE Trans. on Power Delivery*, Vol. 18, No. 1, 2003, str. 214-219.
- [16] Zajczyk R., Modele matematyczne systemu elektroenergetycznego do badania elektromechanicznych stanów niestabilnych i procesów regulacji. Wydawnictwo Politechniki Gdańskiej, 2003.
- [17] Żmuda K., Elektroenergetyczne układy przesyłowe i rozdzielcze. Wybrane zagadnienia z przykładami. Wydawnictwo Politechniki Śląskiej, 2012.



INNOVATIVE ECONOMY
NATIONAL COHESION STRATEGY



EUROPEAN UNION
EUROPEAN REGIONAL
DEVELOPMENT FUND



The "Development of Novel Ultra Low Power, Parallel Artificial Intelligence Circuits for the Application in Wireless Body Area Network Used in Medical Diagnostics" project is realized within the POMOST programme of Foundation for Polish Science, cofinanced from European Union, Regional Development Fund

**A CONCEPT OF THE APPLICATION OF ARTIFICIAL NEURAL NETWORKS
IN THE LOCATION OF ELEMENTS THAT DISTORT THE QUALITY
OF ENERGY IN MEDIUM VOLTAGE DISTRIBUTION NETWORKS**

The paper presents a concept of using artificial neural networks to solve the problem of the location of sources that cause deterioration in the quality of the electrical power. In this field the solutions that base on artificial intelligence are gaining popularity in recent time. However, the learning algorithms that are used in this case are usually implemented as computer programs. Given the large amount of data that must be processed, such solutions are not optimal. The solution to this problem may be the usage of parallel data processing obtainable in neural networks implemented, for example, as specialized integrated circuits. This is the purpose of our research. This paper presents one of the important steps in this task - a model of the electrical power system, the aim of which is to provide training data for the neural network. In the realized neural network a novel algorithm has been used that is based on filtering of the quantization error. By using this algorithm the learning phase can be substantially shortened, so that the network is able to quickly adapt to new data.