

Przegląd i perspektywy zastosowań sztucznej inteligencji w nieinwazyjnej identyfikacji odbiorników energii elektrycznej

Streszczenie. W artykule przedstawiono analizę możliwości wykorzystania metod sztucznej inteligencji do nieinwazyjnej identyfikacji odbiorników energii elektrycznej w budynku mieszkalnym. Omówione zostały techniki akwizycji danych pomiarowych, będące podstawą do tworzenia zbiorów uczących i pozyskiwania wiedzy dla algorytmów inteligentnych. Zaprezentowano taksonomię obecnie stosowanych podejść do automatycznego rozpoznawania odbiorników, a także zaproponowano autorskie rozwiązania problemu.

Abstract. The paper presents the analysis of the artificial intelligence applications for the non-invasive identification of electrical energy appliances in the residential premises. The data acquisition techniques are discussed, being the source of the training data and knowledge for the intelligent algorithms. Taxonomy of the currently used approaches is also introduced. The new methods, not used so far for the task are also proposed. (**State of the art and perspectives of the artificial intelligence usability in the non-invasive identification of electrical energy appliances**).

Słowa kluczowe: identyfikacja odbiorników, zużycie energii, sztuczna inteligencja, metody nieinwazyjne.

Keywords: appliances identification, energy consumption, artificial intelligence, non-intrusive methods.

doi:10.12915/pe.2014.11.03

Wstęp

Określenie poziomu zużycia energii elektrycznej w gospodarstwach domowych jest jednym z zadań stojących przed współczesnym sektorem energetycznym. Polityka państw rozwiniętych ma na celu minimalizację pobieranej energii w szczególności przez odbiorniki w budynkach mieszkalnych, co w połączeniu z przejściem na źródła odnawialne, ma zahamować i odwrócić niekorzystne tendencje w środowisku naturalnym (np. efekt cieplarniany). Z tego powodu kładzie się nacisk na możliwości identyfikacji poszczególnych odbiorników, co może ułatwić ustalenie, które urządzenia są odpowiedzialne za największe zużycie energii. Ponadto możliwe stałoby się stworzenie profilu energetycznego typowego użytkownika.

Celem artykułu jest przedstawienie aktualnego stanu wiedzy na temat metod identyfikacji urządzeń działających w domu na podstawie pomiaru parametrów w sieci energetycznej. Ponieważ skuteczność omawianych podejść zależy istotnie od dostarczonych danych, w następnym punkcie omówiono architekturę systemu, rodzaje odbiorników spotykanych w mieszkaniach oraz mierzone wielkości, które umożliwiają rozróżnianie pomiędzy poszczególnymi odbiornikami. Następnie zawarto charakterystykę metod sztucznej inteligencji stosowanej do przedstawionego problemu. Opisano tu również klasyfikację algorytmów dotąd stosowanych. Na końcu umieszczono propozycje zastosowania metod dotąd nie używanych oraz wnioski na temat perspektyw systemów identyfikacyjnych.

Architektura systemu pomiarowego

System nieinwazyjnej identyfikacji odbiorników energii elektrycznej (Rys. 1) obejmuje jedno urządzenie umieszczone w pobliżu skrzynki zbiorczej oraz miernika energii elektrycznej. Identyfikacja jest realizowana na podstawie pomiarów w jednej lokalizacji. Jest to system monitorowania nieinwazyjnego (ang. Non-Intrusive Load Appliance Monitoring - NIALM), w którym nie wymaga się ingerencji w instalację elektryczną budynku, co znacząco upraszcza strukturę systemu. Wadą rozwiązania jest ograniczenie rozróżnialności między poszczególnymi urządzeniami w stosunku do systemów inwazyjnych, w których możliwe są pomiary w pobliżu każdego urządzenia oddzielnie. W zależności od zastosowanego sprzętu pomiarowego, możliwe jest pozyskiwanie odmiennych rodzajów parametrów, na podstawie których można identyfikować odbiorniki. W najstarszym podejściu [1] zakładano pomiary składowej rzeczywistej i urojonej mocy

pobieranej przez urządzenia, obecnie dokonuje się akwizycji wielu dodatkowych parametrów zarówno w dziedzinie czasu, jak i częstotliwości.

Proponowane metody pomiaru parametrów elektrycznych uzależnione są od rodzaju badanych odbiorników. W [2] wyróżniono cztery rodzaje urządzeń:

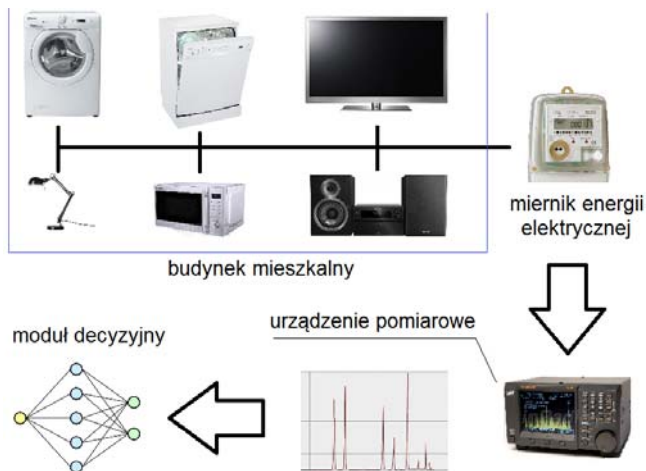
- Pracujące w trybie stałego poboru mocy, tzn. nigdy nie wyłączane (np. instalacje przeciwpożarowe)
- Pracujące w trybie dwustanowym (włączone/wyłączone), np. telewizor. Ich analiza wymaga wykrycia momentu włączenia lub wyłączenia odbiornika, co wiąże się, odpowiednio, ze skokiem i spadkiem pobieranej mocy.
- Skończone maszyny stanów (ang. finite state machines), tzn. pracujące w kilku trybach, pomiędzy którymi można zaobserwować zmiany w poziomie pobieranej mocy (np. pralki).
- Pracujące w trybie ciągłym, gdzie nie da się wyróżnić dyskretnych trybów pracy (np. wiertarki udarowe). Jest to grupa najtrudniejsza do identyfikacji.

Artykuł dotyczy trzech pierwszych rodzajów (ze względu na ich rozpowszechnienie w mieszkaniach). Monitorowanie urządzeń odbywa się na podstawie danych pozyskanych przez urządzenie pomiarowe (Rys. 1), obejmujących:

- Składową rzeczywistą i urojoną mocy pobieranej (uzyskiwana na podstawie pomiaru prądu płynącego przez impedancję o znanej wartości) [1]
- Charakterystyczne wielkości związane z analizą sygnału elektrycznego w dziedzinie czasu: wartość maksymalna, minimalna, międzyszczytowa, RMS, stopień wypełnienia itp. [3]
- Cechy widma amplitudowego, np. amplituda prąжка częstotliwości podstawowej i dla składowych harmonicznych [4].
- Parametry związane z zakłóceniami na wysokich częstotliwościach (rzędu dziesiątek lub setek kHz), generowane przez odbiorniki wyposażone w zasilacze impulsowe (tzw. EMI) [5].
- Parametry stanów przejściowych pomiędzy poszczególnymi trybami pracy. W większości odbiorników wzrost poboru mocy nie ma charakteru natychmiastowej zmiany do poziomu końcowego. Polega na stopniowym osiągnięciu wartości docelowej, poprzedzonym impulsem o dużej wartości [6].

Identyfikacja urządzeń oparta jest na wykryciu określonych zdarzeń w szeregu czasowym na podstawie analizy wymienionych parametrów. Pozyskiwanie tych

ostatnich związane jest z koniecznością próbkowania sygnałów prądu i/lub napięcia z rosnącą częstotliwością (od 1Hz [1], poprzez 25kHz [4], do pojedynczych MHz [5]). Każda grupa pomiarów zawiera inne informacje, w celu maksymalizacji skuteczności identyfikacji konieczne jest mierzenie maksymalnej ich liczby.



Rys. 1. Architektura nieinwazyjnego systemu identyfikacji odbiorników energii elektrycznej

Zastosowanie sztucznej inteligencji w NIALM

Wykorzystanie sztucznej inteligencji do automatycznej identyfikacji odbiorników wymaga zgromadzenia informacji na temat zachowania poszczególnych urządzeń w wybranych trybach pracy. W tym celu konieczne jest stworzenie zbiorów danych w warunkach laboratoryjnych. W wyniku pomiarów kolejnych urządzeń (analizowanych pojedynczo w celu uproszczenia procesu) uzyskuje się zbiory sygnatur (przykłady) $S = \{s_1, s_2, \dots, s_m\}$, na podstawie wielkości przedstawionych w punkcie 2. Każdy przykład otrzymuje etykietę identyfikującą odbiornik, z którym powiązana jest sygnatura s_i . W ten sposób tworzone są zbiory danych trenujących L , będące źródłem wiedzy dla metod inteligentnych:

$$(1) \quad L = \begin{bmatrix} s_1 & d_1 \\ \vdots & \vdots \\ s_n & d_n \end{bmatrix} = \begin{bmatrix} s_{11} & s_{1m} & d_1 \\ \vdots & \vdots & \vdots \\ s_{n1} & s_{nm} & d_n \end{bmatrix}$$

gdzie d_1, \dots, d_n to identyfikatory poszczególnych stanów odbiorników (jedno urządzenie może być reprezentowane przez wiele sygnatur). Na podstawie takich zbiorów należy przygotować moduł decyzyjny (Rys. 1), rzutujący wektor cech pobranego przez urządzenie pomiarowe w chwili t na dyskretne wartości identyfikujące odbiorniki:

$$(2) \quad d = f(s(t)): s(t) \rightarrow d, d \in Z$$

Jest to zatem zadanie klasyfikacji obiektów, wymagające cyklicznego powtarzania pomiarów w celu wykrycia zmiany w poborze mocy, co sugeruje włączenie odbiornika, wyłączenie go lub zmianę trybu pracy. Następujące problemy mogą utrudnić pracę inteligentnego modułu decyzyjnego:

- Zbiór L jest przygotowywany tak, aby możliwe było wykrywanie pojedynczych urządzeń, możliwa jest jednak zmiana stanów k odbiorników pomiędzy sąsiednimi pomiarami. Powinny one zostać wykryte na podstawie wektora pomiarowego przedstawiającego złożenie (superpozycję) kilku sygnatur:

$$(3) \quad s(t) = s_1(t) + s_2(t) + \dots + s_k(t)$$

- Możliwe jest istnienie grup odbiorników nierozróżnialnych na podstawie zmierzonych parametrów. Grupy takie powinny zostać zidentyfikowane i opisane na etapie uczenia modułu.
- Ze względu na ogromną liczbę odbiorników wykrywanie wszystkich modeli i typów może być trudne ze względu na konieczność przeanalizowania w laboratorium każdego egzemplarza. Z tego powodu rozsądne jest ograniczenie się na początku do rozróżniania ogólnych rodzajów odbiorników.
- Obecność szumu pochodzącego z instalacji elektrycznej (np. z sąsiednich mieszkań lub budynków), utrudniającego klasyfikację, co wymaga zastosowania operacji odszumiania mierzonych sygnałów elektrycznych, a także metod wstępnego przetwarzania danych (np. analizy głównej składowej).



Rys. 2. Klasyfikacja metod sztucznej inteligencji wykorzystywanych w NIALM

Na Rys. 2 przedstawiono metody sztucznej inteligencji wykorzystywane w NIALM. Najpopularniejsze jest uczenie z nadzorem, bezpośrednio stosowane do klasyfikacji odbiorników. Rys. 2 przedstawia ich rozróżnienie ze względu na formę przechowywanej wiedzy. Do metod numerycznych zaliczane są sieci neuronowe (perceptrony wielowarstwowe oraz sieci RBF), a także maszyny wektorów podpierających (ang. Support Vector Machines - SVM). Skuteczność perceptronów została najlepiej rozpoznana [2], zaś zaletą sieci SVM jest duża dokładność w warunkach niepewności pomiarowej. Problemem wykorzystania sieci neuronowych do klasyfikacji jest wybór metody kodowania identyfikatorów urządzeń za pomocą neuronów o binarnych funkcjach aktywacji. Schemat „jeden-przeciw-wszystkim” (ang. „One-vs-All”) może być najbardziej skuteczny, choć wymaga największej liczby jednostek w warstwie wyjściowej. Alternatywą jest np. kodowanie minimalizujące liczbę neuronów (MOC).

Metody regulowe obejmują drzewa i lasy decyzyjne (ang. decision forest) oraz algorytmy indukcji reguł. Do ich implementacji stosowano dobrze znane biblioteki programistyczne (np. Weka). Zaletą tej grupy jest zrozumiała dla człowieka forma przechowywania wiedzy oraz efektywne algorytmy uczenia. Logika rozmyta (ang. Fuzzy Logic) [7] stanowi rozwinięcie reguł poprzez uwzględnienie warunków niepewności pomiarowej.

Metody probabilistyczne opierają się na uprzednim określeniu prawdopodobieństw a priori zaistnienia sygnatur obserwowanych dzięki urządzeniom pomiarowym. W przypadku naiwnego klasyfikatora Bayesa obliczane są one

z danych trenujących. Sieci Bayesowskie oraz ukryte łańcuchy Markowa [8] zakładają istnienie eksperta, który może podać je z wymaganą dokładnością.

Metody hybrydowe obejmują rozwinięcie podejść opisanych powyżej. W ich skład wchodzi przede wszystkim rozmyte sieci neuronowe (ang. Fuzzy Neural Networks - FNN) stanowią połączenie logiki rozmytej oraz sieci neuronowych [9]. Ta pierwsza zapewnia wysoką dokładność w obecności szumu pochodzącego ze środowiska zewnętrznego, zaś sieci umożliwiają automatyczną generację reguł (reguł oraz wejściowych i wyjściowych funkcji przynależności). Do tej grupy mogą należeć również inne kombinacje, łączące algorytm uczenia maszynowego z właściwościami systemu ekspertowego (np. drzewa decyzyjne oraz logikę rozmytą [10]). Takie rozwiązania nie były dotąd stosowane w NIALM.

Podejście słownikowe jest prostą i atrakcyjną metodą, wykorzystaną np. do identyfikacji odbiorników na podstawie analizy zakłóceń EMI. Wymaga ona obliczenia odległości między przykładami znajdującymi się w bazie danych oraz sygnaturą właśnie pozyskaną z mieszkania lub budynku. Identyfikator najbliższych przykładów są wykorzystywane podczas podejmowania decyzji. Najpopularniejszą metodą tego typu jest k najbliższych sąsiadów (kNN).

Metody uczenia bez nadzoru są wykorzystywane na dwa sposoby. Pierwszy to grupowanie sygnatur i tworzenie na tej podstawie grup (ang. clusters) charakteryzujących poszczególne kategorie odbiorników, trudno rozróżnianych na podstawie danych pomiarowych. Po stworzeniu kategorii, ich cechy charakterystyczne są wykorzystywane do identyfikacji urządzeń. Drugie zastosowanie ma charakter pomocniczy dla metod klasyfikacyjnych (np. FNN). Ich zadaniem jest pogrupowanie podobnych przykładów, umożliwiające utworzenie reguł. Do najczęściej wykorzystywanych należy metoda rozmytych średnich (ang. fuzzy means clustering) oraz grupowanie średnich przesuniętych (ang. mean shift clustering) [11].

Metody optymalizacyjne są stosowane do uzyskania najdokładniejszego skończonej maszyny stanów. Jest ona reprezentowana np. przez ukryte łańcuchy Markowa, zaś do jej dopasowania do problemu zaproponowano programowanie dynamiczne (wraz z modyfikacją – algorytmem Viterbiego). Metodą standardowo wykorzystywaną do tego celu jest też algorytm genetyczny, analizujący wiele konfiguracji maszyny stanów naraz.

Analiza i wnioski

Metody sztucznej inteligencji stosowane są w NIALM dość powszechnie ze względu na dostępność ich implementacji programistycznych oraz łatwość pozyskiwania wiedzy ze zbiorów trenujących. Dotychczasowe przykłady zastosowań każą zauważyć problemy wymagające rozwiązania w toku badań:

- Poszczególne metody są stosowane w konkretnych, szczególnych przypadkach, brak natomiast ogólnej analizy porównawczej całych grup podejść. Dla przykładu, należałoby porównać metody numeryczne, probabilistyczne oraz regułowe. Celowe może być stworzenie fuzji klasyfikatorów, obejmujących różne metody głosujące równolegle.
- W arsenale proponowanych metod brakuje kilku algorytmów zyskujących ostatnio na popularności. Systemy regułowe mogą zostać wzbogacone o zbiory przybliżone (ang. Rough Sets), które są przydatne np. w diagnostyce technicznej. Z kolei w uczeniu bez nadzoru można wykorzystać samoorganizujące się mapy (ang. Self-Organizing Maps) oraz grupowanie grafowe (ng. Graph Clustering). W zadaniach optymalizacji

dyskretnej może zostać wykorzystany algorytm mrówkowy (ang. Ant Colony Optimization).

- Zbiór odbiorników, na których stosowano metody klasyfikacyjne jest niewielki. W celu wyciągnięcia ogólnych wniosków na temat ich przydatności konieczne może okazać się przeprowadzenie intensywnych eksperymentów laboratoryjnych w celu pozyskania maksymalnej liczby sygnatur. Ze względu na znaczne koszty związane z tworzeniem takiego zbioru, celowe jest tworzenie rozproszonej bazy danych, uzupełnianej przez zespoły badawcze z różnych ośrodków.

Technologia NIALM wymaga jeszcze szeroko zakrojonych prac, obejmujących pozyskiwanie danych pomiarowych oraz ich przetwarzanie. Efektem prac powinno być stworzenie uniwersalnego systemu klasyfikacyjnego implementowanego w typowym budynku. Należy podkreślić, że w związku z pojawianiem się kolejnych modeli poszczególnych odbiorników, konieczne będzie cykliczne uzupełnianie wiedzy modułu klasyfikacyjnego.

Praca wykonana w ramach projektu badawczego NCBiR PBS2/A4/8/2013

LITERATURA

- [1] Zeifman M., Roth K., Nonintrusive Appliance Load Monitoring: Review and Outlook, *IEEE Trans. Consumer Electronics*, Vol. 57 (2011), n. 1, 76-84
- [2] Figueiredo M., Almeida A., Ribeiro B., Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems, *Neurocomputing*, 96 (2012), 66–73
- [3] Tsai M. S., Lin Y. H., Development of a Non-Intrusive Monitoring Technique for Appliance Identification in Electricity Energy Management, The International Conference on Advanced Power System Automation and Protection, 2011, 108-113
- [4] Jiang L., Luo S., Li J., Automatic power load event detection and appliance classification based on power harmonic features in nonintrusive appliance load monitoring, 8th IEEE Conf. Industrial Electronics and Applications (ICIEA), 2013, 1083-1088
- [5] Gupta S., Reynolds M. S., Patel S. N., ElectriSense: Single-Point Sensing Using EMI for Electrical Event Detection and Classification in the Home, 12th ACM International Conf. Ubiquitous Computing, 2010, 139-148
- [6] Alles H., Zenger B.A., A Commercial Disaggregation System for Residential and Light Commercial Buildings, 2nd NILM Workshop, Austin, Texas, 3 June 2014
- [7] Kamat S.P., Fuzzy logic based pattern recognition technique for non-intrusive load monitoring, IEEE Region 10 Conference (TENCON), 21-24 Nov. 2004 Chiang Mai, Vol. C, 528-530
- [8] Kolter J.Z., Jaakkola T., Approximate Inference in Additive Factorial HMMs with Application to Energy Disaggregation, 15th International Conf. Artificial Intelligence and Statistics, La Palma, Canary Islands, Vol. XX, 2012
- [9] Lin Y.-H., Tsai M.-S., Application of Neuro-Fuzzy Pattern Recognition for Non-intrusive Appliance Load Monitoring in Electricity Energy Conservation, WCCI 2012 IEEE World Congress on Computational Intelligence, June, 10-15, 2012
- [10] Bilski P., Wojciechowski J., Automated Diagnostics of Analog Systems Using Fuzzy Logic Approach, *IEEE Trans. Instr. and Meas.*, 56 (2007) N. 6, 2175-2185
- [11] Zhenyu W., Guilin Z., The application of mean-shift cluster in residential appliance identification, 30th Chinese Control Conference (CCC), 2011

Autorzy: dr hab. inż. Piotr Bilski, Politechnika Warszawska, Instytut Radioelektroniki, ul. Nowowiejska 15/19, 00-650 Warszawa, E-mail: pbilski@ire.pw.edu.pl; mgr inż. Krzysztof Liszewski, Politechnika Warszawska, Instytut Radioelektroniki, ul. Nowowiejska 15/19, 00-650 Warszawa, E-mail: krzysztof.liszewski1@gmail.com; prof. dr hab. inż. Wiesław Winięcki, Politechnika Warszawska, Instytut Radioelektroniki, ul. Nowowiejska 15/19, 00-650 Warszawa, E-mail: W.Winięcki@ire.pw.edu.pl.