

## Analiza zborności parametrów odbiorników energii elektrycznej w kontekście bezinwazyjnej identyfikacji urządzeń

**Streszczenie.** *Bezinwazyjny monitoring obciążenia (Non-Intrusive Load Monitoring - NILM) jest systemem wspomagającym decyzje ukierunkowane na zmniejszenie zużycia energii elektrycznej w gospodarstwach domowych i obiektach komercyjnych. Głównym zadaniem w tym systemie jest identyfikacja urządzeń elektrycznych wykorzystująca analizę zdarzeń występujących w instalacji domowej lub poprzez analizę jej stanu ustalonego. W przypadku analizy stanu ustalonego istotny jest dobór parametrów elektrycznych, które w jednoznaczny sposób opisują pracujące urządzenia. W pracy przedstawiono analizę szerokiego spektrum parametrów elektrycznych (prąd, napięcie, moce oraz harmoniczne tych sygnałów, THD, CF, PF) w celu wskazania, które z nich charakteryzują się największą stabilnością w obrębie danego urządzenia oraz jak największą separowalnością wobec innych urządzeń. Tak wybrane parametry w kolejnym kroku wykorzystano do identyfikacji pracujących urządzeń elektrycznych.*

**Abstract.** *The main objective of Non-Intrusive Load Monitoring (NILM) electrical appliance identification is to reduce residential and commercial electricity consumption. This identification can be based on the analysis of events occurring in the home system or by analyzing its steady state. In the case of steady-state analysis, it is necessary to select electrical parameters that uniquely describe the electrical equipment in operation. This paper presents an analysis of a wide spectrum of electrical parameters (current, voltage, powers and harmonics of these signals, THD, CF, PF) in order to indicate those that are characterized by the greatest consistency within a given device and the greatest separability from other devices. Parameters selected in this way were used in the next step to identify working electrical devices. (Analysis of the coherence of parameters of electricity receivers in the context of non-invasive device identification)*

**Słowa kluczowe:** bezinwazyjna identyfikacja urządzeń, cechy identyfikacyjne, selekcja cech, sieci neuronowe.

**Keywords:** device identification, identification features, feature selection, neural networks.

### Wstęp

Urządzenia elektryczne są najpowszechniejszymi urządzeniami wykorzystywanymi w życiu codziennym. Spotykamy je zarówno w gospodarstwach domowych w postaci AGD, RTV czy małych elektronarzędzi, w biurach, w placówkach handlowych i w fabrykach. Powszechność ich wykorzystania wynika z dużej ich niezawodności oraz relatywnie niewysokich cen zakupu i eksploatacji. W gospodarstwach domowych, biurach i handlu wykorzystywane są urządzenia niewielkiej mocy (od kilku W do kilku kW), w przemyśle można spotkać urządzenia o mocach znacznie większych (nawet rzędu MW). Wszystko to powoduje, że pomimo, iż nowe urządzenia są mniej energochłonne to ciągle wzrasta zapotrzebowanie na energię elektryczną. Tendencje tą można ograniczyć wyłączając niepotrzebnie pracujące urządzenia elektryczne, których jak pokazują badania, może być w wymiarze energetycznym nawet do 20% w gospodarstwach domowych [1] oraz po kilka, kilkanaście procent w obiektach biurowych i różnego rodzaju instytucjach. Zmniejszenie energochłonności spowoduje nie tylko obniżenie kosztów życia czy zmniejszenie inwestycji w energetyce ale pozwoli również lepiej zadbać o naturalne środowisko.

Obniżenie energochłonności można uzyskać poprzez wyłączenie zbędnie pracujących urządzeń, o czym wspomniano wcześniej, zaś poprawę równomierności obciążenia energetycznego w czasie poprzez przesunięcie pracy niektórych urządzeń na godziny mniejszego obciążenia systemów energetycznych (np. na noc). Aby jednak stało się to możliwe konieczne jest uświadomienie konsumentom energii, że część ponoszonych przez nich kosztów można wyeliminować. W tym celu należy zidentyfikować pracujące urządzenia elektryczne.

Identyfikacja urządzeń może być przeprowadzona w trybie inwazyjnym – Intrusive Load Monitoring (ILM) lub bezinwazyjnym – Non-Intrusive Load Monitoring (NILM) [2, 3]. Metoda ILM polega na pomiarze poboru mocy w każdym

punkcie w którym podłączono urządzenia elektryczne. Co czyni ją metodą bardzo dokładną, a jeżeli dodatkowo zastosuje się inteligentne gniazda sieciowe skomunikowane z urządzeniem centralnym można uzyskać wygodny system monitorowania obciążenia wykorzystujący Internet of Things. Wadą tego rozwiązania jest konieczność stosowania dużej liczby elementów z czym związane są określone koszty. Alternatywna metoda (NILM) bazuje na pomiarach w jednym, centralnym punkcie zasilania obiektu [4], dzięki czemu jest znacznie tańsza, ale niestety znacznie trudniejsza do zaimplementowania ze względu na konieczność rozdziału zbiorczej energii na poszczególne, aktualnie pracujące urządzenia.

Ważnymi elementami bezinwazyjnej identyfikacji urządzeń są pomiary, a właściwie częstotliwość próbkowania mierzonych sygnałów, dobór cech oraz metody identyfikacji. Na potrzeby NILM najczęściej dzieli się pomiary na niskoczęstotliwościowe (do ok. 1Hz) i wysokoczęstotliwościowe (od 1 Hz do kilkudziesięciu KHz) [2, 5]. Pomiary wykonywane z niską częstotliwością nie dają możliwości wykorzystania harmonicznych prądów i mocy oraz wielkości od nich zależnych. W sytuacji, gdy coraz więcej pracujących urządzeń elektrycznych ma charakter nieliniowy parametry te mogą być istotnym źródłem informacji. Jednak, aby mieć do nich dostęp częstotliwość próbkowania podczas pomiarów musi być wystarczająco duża.

W większości przypadków autorzy dobierają cechy identyfikacyjne w sposób arbitralny decydując się najczęściej na moc czynną (P), rzadziej na moc bierną (Q), pozorną (S) i natężenie prądu (I) co pokazano w pracy [6]. Do rzadkości należą prace, w których dobór cech odbywa się z wykorzystaniem znanych metod selekcji [7-9]. Ostatni etap przetwarzania w systemie NILM to identyfikacja pracujących urządzeń elektrycznych i może ona być zrealizowana z wykorzystaniem metod sztucznej inteligencji takich jak:

- sztuczne sieci neuronowe (MLP, RBF, SVM), uczone metodami nadzorowanymi i nienadzorowanymi [2, 7, 10, 11, 12] w tym sieci uczone głęboko [6, 13];
- metody statystyczne, takie jak naiwny klasyfikator Bayesa czy ukryte łańcuchy Markowa [2, 13, 14];
- metoda k-najbliższych sąsiadów [2, 15, 17]
- metody regałowe (drzewa i lasy decyzyjne, algorytmy indukcji reguł, metody logiki rozmytej) [2, 3, 17];
- algorytmy genetyczne [16];
- metody hybrydowe – stanowiące dowolne kombinacje wymienionych wyżej metod [2, 18].

### Analiza parametrów opisujących pracujące urządzenia elektryczne

Warunkiem koniecznym do przeprowadzenia bezinwazyjnej identyfikacji urządzeń elektrycznych jest dobór parametrów identyfikacyjnych. W metodzie wykorzystującej stany ustalone możliwe jest wykorzystanie bardzo szerokiego spektrum cech i ich pochodnych.

### Odbiorniki energii elektrycznej i ich opis

W niniejszej pracy przeprowadzono identyfikację ośmiu rodzajów urządzeń elektrycznych działających w różnych warunkach pracy. Identyfikacji poddano: kuchenki mikrofalowe, odkurzacze, miksery, laptopy, tostery, suszarki do włosów, telewizory oraz żelazka. Wstępnie urządzenia opisano przy pomocy 168 parametrów, które obejmowały wartości skuteczne napięcia (U) i prądu (I), składowe podstawowe oraz wysokie mocy czynnej ( $P_1$ ,  $P_h$ ), biernej ( $Q_1$ ,  $Q_h$ ) i pozornej ( $S_1$ ,  $S_h$ ), współczynniki odkształcenia napięcia (THD<sub>U</sub>) i prądu (THD<sub>I</sub>), współczynniki szczytu napięcia (CF<sub>U</sub>) i prądu (CF<sub>I</sub>) oraz 50 pierwszych składowych prądu ( $I_{1÷I_{50}}$ ), mocy czynnej ( $P_{2÷P_{50}}$ ) i mocy biernej ( $Q_{2÷Q_{50}}$ ). Liczba harmonicznych uwzględnionych w analizach została dobrana zgodnie z zaleceniami norm EN 50160 oraz IEC 61000-4-15 (PN-EN-61000-4-30) przedstawiających metodologię pomiarów oraz

określających wymagania odnośnie przyrządów wykorzystywanych do badania jakości energii w tym odkształcenia prądów i napięć. Dane wykorzystane w badaniach zostały pozyskane przy pomocy analizatora jakości energii Elspec BlackBox 4500.

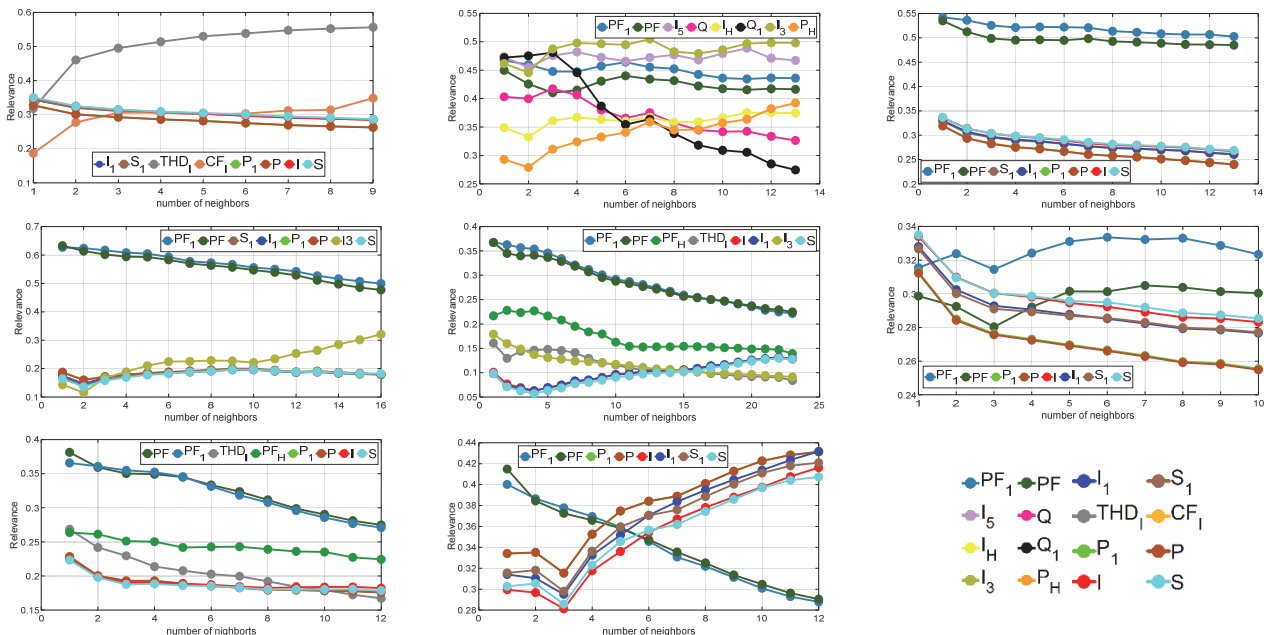
### Selekcja cech - Metoda ReliefF

Celem selekcji cech jest zmniejszenie wymiaru zbioru parametrów opisujących obiekt (dane). Polega ona na wyborze, pod kątem przydatności do dalszego wykorzystania w klasyfikacji (identyfikacji), niektórych atrybutów opisujących dane, a odrzuceniu innych. Istnieje wiele metod selekcji cech. W niniejszej pracy, w celu redukcji wektora wejściowego opisującego poszczególne urządzenia elektryczne wykorzystano algorytm ReliefF, stanowiący modyfikację metody Relief.

Algorytmy typu Relief oparte są na podobnym pomysłu, jak klasyfikator kNN, którego działanie polega na analizie k najbliższych sąsiadów z otoczenia klasyfikowanego punktu i zaliczenia go do klasy najliczniej reprezentowanej. W przypadku selekcji sprowadza się to do promowania tych cech, dla których sąsiedzi należą do tej samej klasy, co rozważany wektor treningowy, są blisko, a sąsiedzi z innych klas — daleko.

Miara istotności atrybutu ( $w_f$ ) w metodzie ReliefF jest wyznaczana dla obserwacji zebranych w  $n$  elementowym zbiorze treningowym. Dla każdego punktu  $x$  z tego zbioru znajdujących jest  $k$  najbliższych sąsiadów z tej samej klasy, zwanych trafieniami ( $h$ ) oraz  $k$  najbliższych sąsiadów z pozostałych klasy, zwanych chybieniami ( $m$ ). Następnie dla każdej cechy  $f$  waga jest powiększana o odległość  $x$  od  $m$  i pomniejszana o odległość  $x$  od  $h$  [19]:

$$(1) \quad w_f(m, k) = \frac{1}{nk} \sum_{i=1}^n (\sum_{j=1}^k |x_i, m_{ij}| - \sum_{j=1}^k |x_i, h_{ij}|)$$




Rys.1. Zmiany wartości współczynników istotności najważniejszych wyselekcjonowanych cech dla badanych urządzeń, w zależności od liczby analizowanych sąsiadów (od góry w lewo: laptop, mikrofała, mikser, odkurzac, suszarka, telewizor, toster, żelazko).

### Wyniki selekcji cech

Selekcja cech została przeprowadzona dla każdego z wymienionych wcześniej urządzeń niezależnie. Na rys. 1 pokazano zakres zmian wartości miary istotności wyselekcjonowanych cech dla poszczególnych urządzeń w

zależności od liczby sąsiadów. Im większa wartość miary tym parametr jest istotniejszy, niesie więcej informacji o urządzeniu. Im mniejsze zmiany jego wartości w zależności od liczby sąsiadów tym jest on stabilniejszy (bardziej zborny). Analiza wykresów pozwala stwierdzić, iż

większość wyselekcjonowanych parametrów zachowuje się stabilnie i w niewielkim zakresie zmienia swoje wartości. Największe zmiany wartości współczynników istotności można zaobserwować dla parametrów opisujących żelazka, co ciekawe wraz z liczbą sąsiadów istotność parametrów (za wyjątkiem współczynników mocy) rośnie. Rysunek pozwala, również zauważyć, iż miara istotności cech jest powiązana z typem urządzenia.



Rys.2. Wartości współczynnika istotności analizowanych parametrów w opisie odkurzacza

Analiza rysunku 2 pozwala zauważyć, iż wyższe harmoniczne mocy czynnej oraz mocy bierniej posiadają bardzo niską miarę istotności. Podobnie niską wagę posiadają parametry związane z napięciem tj. wartość skuteczna napięcia ( $U$ ), wartość skuteczna wyższych harmonicznych ( $U_H$ ), współczynnik odkształcenia ( $THD_U$ ) oraz współczynnik szczytu ( $CF_U$ ). Analogiczne wnioski można wyciągnąć przeglądając wartości współczynników istotności parametrów dla pozostałych analizowanych urządzeń.

Tabela 1. Wyselekcjonowane dla poszczególnych urządzeń cechy identyfikacyjne

Parametr	Mikrofalna	Odkurzacz	Mikser	Laptopy	Tostery	Suszarki	TV	Żelazko
$I$		0,18	0,28	0,30	0,18	0,10	0,29	0,36
$I_1$		0,19	0,28	0,30	0,18	0,10	0,29	0,38
$I_H$	0,37							
$I_3$	0,50	0,22				0,11		
$I_5$	0,47							
$THD_I$				0,53	0,20	0,11		
$CF_I$				0,31				
$PF_1$	0,45	0,57	0,52		0,32	0,28	0,33	0,34
$PF$	0,42	0,56	0,50		0,33	0,28	0,30	0,34
$PF_H$					0,24	0,15		0,32
$P$		0,19	0,26	0,28	0,18		0,27	0,39
$P_1$		0,19	0,26	0,28	0,18		0,27	0,39
$P_H$	0,34							
$S_1$		0,18	0,27	0,30	0,18		0,29	0,38
$S$		0,18	0,29	0,31	0,18	0,10	0,29	0,36
$Q$	0,37							
$Q_1$	0,36							

W tabeli 1 zebrano cechy posiadające największe wartości miary istotności dla identyfikacji badanych urządzeń, dla każdego urządzenia wybrano 8 cech (lub więcej gdy były one zbliżone wartości). Analiza zebranych danych pozwala zauważyć, iż dla większości badanych urządzeń parametrami posiadającym dużą wartość miary istotności są współczynniki mocy ( $PF$  i  $PF_1$ ) oraz dla pojedynczych urządzeń (kuchenki mikrofalowe) trzecia harmoniczna prądu ( $I_3$ ) oraz współczynnik odkształcenia prądu ( $THD_I$ ) dla laptopów. Warto również zauważyć, iż w przypadku suszarek wartości miar istotności parametrów są relatywnie małe – wyróżniają się jedynie współczynnik mocy oraz współczynnik mocy pierwszej harmonicznej.

W wyniku selekcji uzyskano zbiór cech identyfikujących będący sumą algebraiczną zbiorów wyselekcjonowanych dla każdego urządzenia niezależnie. Obejmuje on 17 parametrów wyszczególnionych w tabeli 1.

### Identyfikacja pracujących urządzeń elektrycznych

W celu oceny trafności doboru parametrów identyfikacyjnych przeprowadzono proces identyfikacji urządzeń elektrycznych na podstawie wektora cech złożonego z wymienionych 17 parametrów.

### System identyfikacyjny

Do identyfikacji wykorzystano inteligentny system decyzyjny złożony z modułu klasyfikacji wstępnej i bloku decyzyjnego.

Moduł klasyfikacji wstępnej składa się z zespołu 8 sieci neuronowych, z których każda służy do zaklasyfikowania urządzenia do jednej klasy – podaje odpowiedź typu czy wektor identyfikacyjny opisuje dane urządzenie czy nie? Sieci mają identyczną budowę i składają się z 17 neuronów w warstwie wejściowej, 12 w warstwie ukrytej oraz jednego neuronu wyjściowego. Ze względu na brak analitycznych metod pozwalających określić liczebność neuronów warstwy ukrytej, dobór ten dokonano eksperymentalnie. Podobnie dobrano tangensoidalną funkcję przejścia dla tej warstwy, zaś neurony warstwy wyjściowej wyposażono w liniową funkcję przejścia. Do uczenia sieci wykorzystano metodę Levenberga Marquardta charakteryzującą się dużą efektywnością i szybkością uczenia.

Blok decyzyjny ustala ostateczną odpowiedź systemu. Jeżeli tylko jedna z sieci wskazała urządzenie to jest ono rozpoznane i taka odpowiedź jest udzielana na wyjściu systemu. Jeżeli więcej niż jedna sieć wskazuje, że „jej” urządzenie pracuje, to moduł decyzyjny dokonuje porównania wartości odpowiedzi i wskazuje na to, które zostało najmocniej wskazane (największa jest wartość odpowiedzi sieci).

### Wskaźniki oceny jakości identyfikacji

Jakości identyfikacji oceniono przy pomocy trzech wskaźników będących miarą poprawnego rozpoznania: precyzji, czułości i miary  $F1$ .

Precyzja informuje w jakim stopniu możemy zaufać pozytywnym identyfikacjom - jeżeli system wskazuje dane urządzenie to określane jest prawdopodobieństwo podania na wejście systemu sygnału pochodzącego od tego urządzenia. Precyzję opisuje zależność:

$$(2) \quad \text{precyzja} = \frac{TP}{TP+FP}$$

gdzie:  $TP$  (true positive) - obserwacja poprawnie przypisana do analizowanej klasy,  $FP$  (false positive) - obserwacja błędnie przypisana do analizowanej klasy.

Czułość wskazuje z jakim prawdopodobieństwem klasa zostanie rozpoznana prawidłowo (ile próbek zostanie zgubionych) – jeżeli na wejście systemu podamy sygnał pochodzący od konkretnego urządzenia, to z jakim prawdopodobieństwem system rozpozna go prawidłowo:

$$(3) \quad czułość = \frac{TP}{TP+FN}$$

gdzie: FN (false negative) - obserwacja nieprzypisana do klasy mimo, iż do niej należy.

Miara F1 stanowi średnią harmoniczną z precyzji i czułości. Dobór średniej harmonicznnej zamiast arytmetycznej czyni ten wskaźnik bardziej wrażliwym na wyniki bliskie zeru. Dzięki tej właściwości można łatwo zauważyć, że któryś ze wskaźników (precyzja bądź czułość) ma bardzo małą wartość.

$$(4) \quad F1 = \frac{2 \cdot precyzja \cdot czułość}{precyzja + czułość}$$

### Wyniki identyfikacji

W tabeli 2 zebrano wyniki identyfikacji wyrażone przez czułości (3), uzupełnione o wyniki błędnych rozpoznań, ze wskazaniem ich procentowej ilości w podziale na poszczególne urządzenia. Ich analiza wskazuje, iż w przypadku mikserów oraz żelazek uzyskano 100 prawidłowych identyfikacji. Najgorzej wypadła identyfikacja telewizorów, które aż w 10% były identyfikowane jako laptopy oraz suszarki.

Tabela 2. Wartości czułości (na przekątnej) wyrażone w procentach oraz procent błędnie zaliczonych urządzeń do poszczególnych klas

		Urządzenie							
		mikrofala	odkurzacz	mikser	laptop	toster	suszarka	telewizor	żelazko
predykcja	mikrofala	95,0	2,4						
	odkurzacz	3,6	94,1						
	mikser			100,0					
	laptop		2,9		94,0		1,3	10,0	
	toster	1,4				94,6	1,7	0,9	
	suszarka					3,8	89,6	2,7	
	telewizor				3,0		1,7	86,4	
	żelazko						4,6		100,0
	brak		0,6		3,0	1,5	1,3		

Analiza danych zebranych w tabeli 3 pozwala stwierdzić, iż miksery nie tylko w 100% były prawidłowo rozpoznawane ale również, żadne inne urządzenie nie zostało zakwalifikowane jako mikser. Pozostałe urządzenia sporadycznie były mylone, przy czym największym problemem było zaliczanie telewizorów do laptopów.

Tabela 3. Wartości precyzji oraz miary F1

	Urządzenie							
	mikrofala	odkurzacz	mikser	laptop	toster	suszarka	telewizor	żelazko
Precyzja	97,1	97,0	100,0	83,2	94,6	96,4	93,1	92,2
F1	96,0	95,5	100,0	88,3	94,6	92,9	89,6	95,9

### Podsumowanie

W pracy zaprezentowano dobór cech identyfikacyjnych urządzeń elektrycznych wychodząc od bardzo liczego zbioru (168 parametrów). Selekcji dokonano wykorzystując metodą ReliefF opartą na ocenie odległości cech od

najbliższych sąsiadów. Pozwoliło to wyselekcjonować cechy identyfikacyjne jednoznacznie opisujące niektóre urządzenia. Analiza wykazała, iż wyselekcjonowane cechy zachowują stabilne wartości przy zmianie liczby analizowanych sąsiadów.

Badania wykazały, iż poszczególne urządzenia wymagają zastosowania różnych kombinacji zmiennych identyfikujących co doprowadziło do ustalenia 17-elementowych wektorów identyfikacyjnych. Opisy niektórych urządzeń są zbyt słabe (np.: suszarka i wymagają udoskonalenia.

Zaproponowana dwustopniowa metoda identyfikacji ułatwiła uczenie sieci neuronowej i umożliwiła sprawną i poprawną identyfikację urządzeń.

### LITERATURA

- [1] Chui K.T., Lytras M.D., Visvizi, A. Energy Sustainability in Smart Cities: Artificial Intelligence, Smart Monitoring, and Optimization of Energy Consumption. *Energies* (2018), 11, 2869.
- [2] Wójcik A. et al., Nonintrusive Appliance Load Monitoring: An Overview, Laboratory Test Results and Research Directions, *Sensors*, (2019), 19, 3621.
- [3] Le, T.-T.-H.; Kim, H. Non-Intrusive Load Monitoring Based on Novel Transient Signal in Household Appliances with Low Sampling Rate, *Energies* (2018), 11, 3409.
- [4] Hart G.W. Nonintrusive Appliance Load Monitoring. *Proc. IEEE*, (1992), 80, 1870–1891.
- [5] Zhao B., He K., Stankovic L., Stankovic V. Improving Event-Based Non-Intrusive Load Monitoring Using Graph Signal Processing, *IEEE Access*, (2018), 6, 53944-53959.
- [6] Huber P., Calatroni A., Rumsch A., Paice, A. Review on Deep Neural Networks Applied to Low-Frequency NILM. *Energies* (2021), 14, 2390.
- [7] Bartman J., Kwater T. Identification of Electrical Appliances Using Their Virtual Description and Data Selection for Non-Intrusive Load Monitoring *IEEE Transactions on Consumer Electronics*, 67, (2021), no. 4, 393-401.
- [8] Bao S. et al., Feature Selection Method for Nonintrusive Load Monitoring With Balanced Redundancy and Relevancy, *IEEE Transactions on Industry Applications*, 58, (2022), 1, 163-172
- [9] Zhu Z. et al., Feature selection of non-intrusive load monitoring system using RFE and RF, *Journal of Physics: Conference Series*, 1176, (2019), no. 4, 042053.
- [10] Abeykoon V. et al., Real Time Identification of Electrical Devices through Power Consumption Pattern Detection, *First Int. Conf. on Micro and Nano Tech., Mod. and Sim., IEEE Computer Society*, (2016), 11-16.
- [11] Kwater T. Bartman J., Application of artificial neural networks in non-invasive identification of electric energy receivers, *PAEE 2017, Koscielisko*, (2017), pp. 1-6.
- [12] Mohd-Fazzil N.-A. et al., Non-intrusive load monitoring for appliance status determination using feed-forward neural network, *Przegląd Elektrotechniczny*, 98, (2022), no.4, 27-32.
- [13] Singh S., Majumdar A., Non-Intrusive Load Monitoring via Multi-Label Sparse Representation-Based Classification, *IEEE Transactions on Smart Grid*, 11, (2020), no. 2, 1799-1801.
- [14] Makonin S. et al., Exploiting HMM Sparsity to Perform Online Real-Time Nonintrusive Load Monitoring, *IEEE Transactions on Smart Grid*, 7, (2016), no. 6, 2575-2585.
- [15] Khan M. M. R., Siddique M. A. B., Sakib S., Non-Intrusive Electrical Appliances Monitoring and Classification using K-Nearest Neighbors, *2019 2nd International Conference on Innovation in Engineering and Technology*, (2019), 1-5.
- [16] Chui K.T., Lytras, M.D., Visvizi A., Energy Sustainability in Smart Cities: Artificial Intelligence, Smart Monitoring, and Optimization of Energy Consumption. *Energies*, (2018), 11, 2869.
- [17] Lemes D., et al., Load Disaggregation Based on Time Window for HEMS Application, *IEEE Access*, 9, (2021) 70746-70757
- [18] Andrian V., et al., Method of Cascade-Filtering and Committee Decision Mechanism for Non-Intrusive Load Monitoring, *IEEE Access*, 6, (2018), 41212-41223.
- [19] Robnik-Šikonja M., Kononenko I., An adaptation of Relief for attribute estimation in regression. *Machine Learning: Proceedings of the Fourteenth International Conference* (1997) 296-304.