



# Koncepcja zastosowania modelu sieciowego do opisu zachowania konsumentów energii elektrycznej

*Application of complex network model for electricity consumption behavior analysis*

**Streszczenie:** W artykule przedstawiono koncepcję wykorzystania modelu sieci złożonej (ang. complex network) do opisu i analizy zachowań odbiorców energii elektrycznej, na podstawie danych z rzeczywistego systemu. Zaproponowano metodologię tworzenia modelu grafowego na podstawie danych o konsumpcji energii elektrycznej oraz metody jego analizy. Przeprowadzono eksperyment - przykładową analizę z wykorzystaniem danych z rzeczywistego systemu.

**Abstract:** We propose the application of complex network model for representation and analysis of behavior of energy consumers, based on data from real system. Methodology of graph model construction was proposed, along with analysis methods. Experimental analysis using a data from real system was carried out.

**Słowa kluczowe:** sieci złożone, analiza sieciowa, przetwarzanie rozproszone, zużycie energii

**Keywords:** complex networks, network analysis, distributed processing, energy consumption

## Wprowadzenie

Proponowana w niniejszym artykule koncepcja analizy zachowań konsumentów energii elektrycznej oparta jest na istniejących technikach analizy i modelowania złożonych struktur sieci społecznych, powstałych w oparciu o usługi współczesnych systemów teleinformatycznych. Używany wobec nich termin „złożony” jest bezpośrednim odpowiednikiem angielskiego *complex* (*complex networks* – sieci złożone) i oznacza nie tyle skalę i stopień komplikacji (choć z reguły mowa tu o sieciach liczących od tysięcy do milionów węzłów), co fakt, że w systemach tej klasy mamy do czynienia z kolektywnymi zachowaniami, które nie dadzą się bezpośrednio wywieść z opisu poszczególnych komponentów sieci (określa się je często mianem zjawisk i własności emergentnych – ang. *emergent phenomena*).

Zjawiska emergentne w sieciach przejawiają się najczęściej w powstawaniu podlegających obserwacji i analizie struktur na poziomie topologii lokalnej oraz globalnej rozważanej sieci, zależności czasowych widocznych w zachowaniu jej komponentów a także zachowań kolektywnych. Dodatkowo zachodzi tu sprzężenie zwrotne między topologią sieci a jej funkcjami, które z kolei wpływają na strukturę połączeń w sieci – w takich przypadkach mówimy o sieciach adaptacyjnych.

W sytuacji, gdy mamy do czynienia z sieciami, w których rolę węzłów pełnią użytkownicy systemu teleinformatycznego, relacje (powiązania) między nimi powstają wskutek korzystania przez nich z określonych usług systemu [2]. W wielu zastosowaniach relacje w modelach sieciowych definiowane są na podstawie stwierdzonego podobieństwa w zachowaniach użytkowników; to podejście zostanie wykorzystane także w tym artykule [1].

Sieci złożone opisywano i definiowano już wcześniej w ramach modeli wykorzystywanych w wielu obszarach badawczych i dziedzinach nauki – matematyce dyskretniej, informatyce, fizyce statystycznej, biologii, naukach społecznych etc. Jednak dopiero od niedawna mamy do czynienia z równoległe prowadzonymi badaniami sieci powstających na bazie technologii. Ich wyniki mogą zostać następnie wykorzystane do predykcji zachowań użytkowników (tu: odbiorców energii elektrycznej) [8].

Stosowane w tym zakresie metody mają na celu pozyskanie wiedzy o trzech podstawowych strukturalnych aspektach sieci złożonych [7]:

- Pozycja węzła w sieci – określenie jego własności kontekście struktury sieci (stopień węzła, różne rodzaje centralności etc).

- Istnienie grup węzłów – w zależności od przyjętej definicji grupy analizowano zależności między tworzącymi ją węzłami, najczęściej w celu wykrycia kolektywnych zachowań i określenia ich podobieństwa.

- Globalna topologia sieci – zestaw cech wpływających na funkcjonowanie sieci jako całości (spójność, średnica sieci, gęstość połączeń etc.).

W literaturze spotykamy wiele aktualnych przykładów zastosowania modeli sieci złożonych do analizy zachowań odbiorców energii elektrycznej. W pracy [3] zaproponowano model sieciowy pozwalający za predykcję zapotrzebowania na energię w sektorze elektromobilności. Artykuł [4] analizuje modele sieciowe w celu predykcji awaryjności sieci przesyłowych energii elektrycznej. Rynek odbiorców indywidualnych analizowano pod kątem predykcji zapotrzebowania na energię [5] oraz specyficznych potrzeb społeczności lokalnej [6]. Szerszy zakres zastosowań oraz ogólne podejście do tworzenia i analizy złożonych modeli sieciowych opisano (dla różnych kategorii modeli) w pracy [13]. W pracy [14] rozważano stosowalność *Spiking Graph Networks* (SGNs) w modelowaniu rynku konsumentów energii elektrycznej z wykorzystaniem klasyfikacji grafów. W artykule [15] modele grafowe wykorzystano do klasyfikacji i modelowania cyberataków ma infrastrukturę energetyczną. W pracy [16] omówiono ogólne podejście do budowy, utrzymania i adaptacji modeli grafowych w różnych domenach tematycznych.

W niniejszej pracy zaproponowano ogólną metodologię tworzenia modelu sieciowego społeczności odbiorców energii elektrycznej oraz wskazano na możliwości jego zastosowań. Przeprowadzono także szereg eksperymentów na danych pochodzących z realnego systemu, w którym odbiorcami energii są węzły rozproszonego systemu obliczeniowego (*BUTTER Empirical Deep Learning*, wykorzystywanego przez National Renewable Energy Laboratory, USA [9]).

## Dane eksperymentalne

*BUTTER Empirical Deep Learning*, wykorzystywany przez National Renewable Energy Laboratory, USA [9] jest zaawansowanym zestawem danych eksperymentalnych, obrazującym zużycie energii. Dane w zestawie BUTTER-E

są zbierane z pojedynczych mierników zużycia energii (watomierzy), obejmując 63,527 pojedynczych eksperymentów. W wykorzystanym zbiorze danych odbiorcami (konsumentami) energii elektrycznej są węzły (serwery) rozproszonego systemu obliczeniowego, realizującego eksperymenty z zakresu uczenia maszynowego. Poszczególne dane zostały zebrane w różnorodnych zestawach, co pozwala na analizę zużycia energii w kontekście zastosowania różnych modeli sieciowych i algorytmów. Dzięki temu możliwe jest dokładne śledzenie i porównywanie wydajności energetycznej w różnych scenariuszach i architekturach.

Do eksperymentu wybrano reprezentatywne dane, obejmujące zużycie energii dla każdego węzła zestawione w postaci listy pomiarów, wraz z ich wartością minimalną oraz maksymalną. Zestaw danych umieszczony został w pliku *node\_power\_dist.csv*. Pobrane dane przygotowano do dalszej analizy poprzez wybór wartości zużycia energii odpowiednio minimalnych oraz maksymalnych, dla każdego węzła.

### Budowa modelu sieciowego

W niniejszej pracy proponuje się zastosowanie modeli sieciowych w zadaniu zaawansowanego profilowania odbiorców energii elektrycznej (w tym przypadku: węzłów rozproszonej architektury obliczeniowej). W typowym przypadku metodologia tworzenia modeli sieciowych zakłada przeprowadzenie następujących działań [7]:

1. Zdefiniowanie relacji podobieństwa między obiektami. W naszym przypadku obiekty (węzły architektury obliczeniowej) opisane są wektorami wartości zużycia energii). Relacja podobieństwa między nimi będzie określona za pomocą klasycznej miary odległości euklidesowej, przyjmując wartość 0 gdy zapotrzebowanie węzłów na energię jest identyczne. Celem wykrycia istniejących relacji podobieństwa między węzłami jest identyfikacja odbiorców energii elektrycznej o podobnej charakterystyce zapotrzebowania.
2. Budowa sieci relacji (modelu sieciowego, grafu relacji). Jego wierzchołkami są węzły architektury obliczeniowej,

a krawędzie pojawiają się, gdy zachowanie pary węzłów (w kontekście zapotrzebowania na energię) jest podobne (wartość relacji podobieństwa jest wysoka). W kontekście naszego modelu oznacza to, że miara odległości między węzłami nie przekracza przyjętej w eksperymencie wartości progowej.

3. Analiza grafu w celu wykrycia grup, węzłów o istotnej roli w skali całej sieci itd., a następnie wykorzystanie tej wiedzy w zarządzaniu modelowanym systemem. W przyjętym kontekście węzły zachowujące się podobnie będą tworzyć grupy w strukturze grafu, a węzły o wysokiej centralności będziemy traktować jako reprezentatywne dla całej sieci.

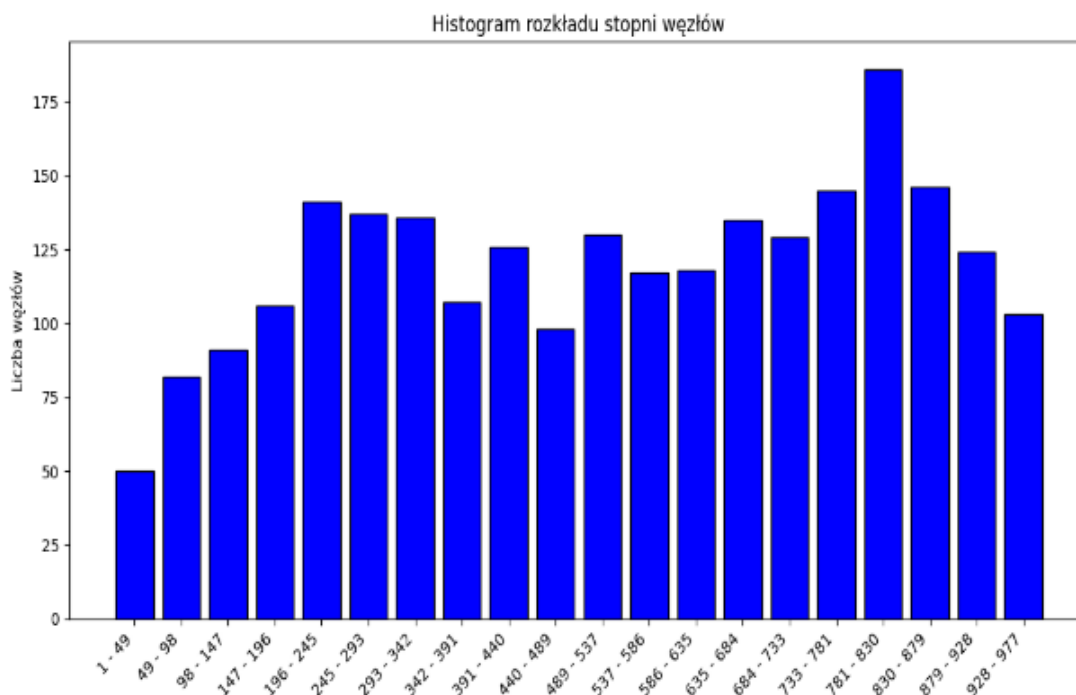
Tak utworzony model sieciowy (grafowy) reprezentuje wzorce zachowań analizowanych obiektów, wraz z relacjami podobieństwa między nimi.

### Eksperymenty

Postępując według metodologii opisanej w poprzedniej sekcji i na podstawie danych ze zbioru [9] utworzono model sieciowy (graf relacji podobieństwa) składający się z 2438 wierzchołków i 23892 krawędzi. Zgodnie z przyjętą metodologią, może on być traktowany jako ogólna reprezentacja relacji podobieństwa między zachowaniem analizowanych obiektów (odbiorców energii).

Na podstawie analizy danych ze zbioru założono, że między zachowaniem węzłów zachodzi istotne podobieństwo gdy odległość euklidesowa między wektorami opisującymi zużycie energii nie przekracza wartości 2.

Stwierdzono liczne podobieństwa między strukturami lokalnych połączeń w bezpośrednim sąsiedztwie węzłów grafu, a w szczególności wysokie wartości stopni węzłów (rys. 1). Oznacza to, że dla większości węzłów istnieją liczne zbiory węzłów sąsiadujących, charakteryzujących się podobnym zachowaniem (profilem zapotrzebowania na energię).



Rys. 1. Histogram rozkładu stopni węzłów

W tak wygenerowanym grafie przeprowadzono operację wykrywania grup (klastrow gęsto połączonych węzłów) z wykorzystaniem algorytmu Louvain opisanego w pracy [10].


Rys. 2. Przedstawia wizualizację modelu sieciowego, przy użyciu algorytmu ForceAtlas2 [11]. Wykryte klastry węzłów oznaczono różnymi kolorami.

Algorytm ten jest przykładem algorytmu typu *force-directed*. Algorytmy *force-directed* ułatwiają wizualizację modeli sieciowych, poprzez rozmieszczenie poszczególnych węzłów uwzględniając symulację różnego rodzaju sił fizycznych pomiędzy nimi.



Rys. 2. Graf relacji podobieństwa

Zasada działania metody ForceAtlas2 polega na symulacji fizycznego modelu oddziaływania między węzłami oraz krawędziami w grafie. Algorytm ten jest ulepszoną wersją klasycznego algorytmu Force-Atlas, jednakże dzięki zastosowaniu metody Barnes-Hut, złożoność obliczeniowa algorytmu zmniejszyła się z  $O(n^2)$  do  $O(n \log n)$ .



Rys. 3. Wizualizacja sieci relacji podobieństwa między konsumentami energii elektrycznej.


Rys. 3. Przedstawia wizualizację (z wykorzystaniem metody Fruchtermana-Reingolda [12]) uzyskanego grafu.

Algorytm ten, podobnie jak poprzedni, również należy do grupy algorytmów typu *force-directed*. Ze względu na fakt, iż zasada jego działania polega na symulacji fizycznego modelu sprężyn oraz sił przyciągania i odpychania pomiędzy poszczególnymi węzłami, pozwala on na bardziej czytelną wizualizację struktury grafu. Dzięki temu dalsza jej analiza jest bardziej intuicyjna. Kolory odpowiadają wykrytym grupom węzłów a wielkości węzłów są proporcjonalne do ich stopnia (liczby sąsiadów). Graf jest grafem zarówno nieskierowanym, jak i niespójnym, a składa się z 51 komponentów, przy czym największy z nich zawiera 92% wszystkich węzłów.

W kontekście założeń przyjętego modelu do każdej z wykrytych grup należą węzły, których zachowanie (w kontekście zapotrzebowania na energię) należy oceniać jako zbliżone (są połączone licznymi relacjami podobieństwa). Konsekwentnie, węzły należące do różnych grup, będą się zachowywać w różny sposób. Jeszcze większe różnice będą miały miejsce w przypadku węzłów należących do różnych komponentów grafu. Komponenty takie są wyraźnie widoczne w jego strukturze (Rys. 4).

Model sieciowy umożliwia zatem grupowanie węzłów z uwzględnieniem ich wzorców zachowań (profilu zapotrzebowania na energię).

Dodatkowo, analiza sieciowa, umożliwia wykrycie węzłów, których charakterystyka może być uznana za typową w skali całego grafu (precyzyjniej: każdego z jego komponentów). W przypadku grafu zbudowanego na podstawie relacji podobieństwa między obiektami, możemy wykorzystać pojęcie tzw. centralności przechodniej (ang.: *betweenness centrality*), definiowanej dla wierzchołka grafu jako frakcja liczby najkrótszych ścieżek pomiędzy wszystkimi parami węzłów w grafie, które przechodzą przez ten wierzchołek. W analizowanym grafie węzły o dużej wartości centralności przechodniej mogą być uznane za połączone licznymi ścieżkami (sekwencjami krawędzi) relacji podobieństwa z maksymalną liczbą innych węzłów, co czyni je reprezentatywnymi.



Rys. 4. Centralność przechodnia węzłów.

Na Rys. 4. widzimy graf o strukturze identycznej z przedstawionym na Rys. 3, jednak wielkość węzła jest proporcjonalna do zmierzonej wartości jego centralności przechodniej. Można zauważyć, że węzłów o wysokiej centralności przechodniej jest stosunkowo niewiele, nie są też równomiernie rozłożone w strukturze wykrytych w grafie



grup. Niezależnie od tego węzły o wysokiej centralności przechodniej mogą być wykorzystane w późniejszej analizie – stanowią przypadki węzłów „typowych”; charakteryzujących się dużą liczbą węzłów o podobnej charakterystyce (ścieżki w grafie łączące takie węzły z innymi są krótkie).

### Podsumowanie

W niniejszym artykule przedstawiono koncepcję powiązania modeli sieciowych, ze szczególnym uwzględnieniem sieci złożonych (ang: *complex networks*) z opisem zachowania odbiorców energii elektrycznej. Przeprowadzony przegląd literatury jednoznacznie potwierdza, że modele sieci złożonych znajdują szerokie zastosowanie do opisu zjawisk różnego typu, a wywodząc się z szeroko rozumianych sieci społecznościowych właściwie odwzorowują zachowania konsumentów.

Przedstawione analizy pozwoliły na sformułowanie wniosków dotyczących zachowań konsumentów energii elektrycznej na podstawie wybranego scenariusza, co wskazuje na realne możliwości praktycznego zastosowania modeli sieciowych w identyfikacji wzorców zużycia energii.

### Dalsze prace

Przegląd literatury, istotność tematyki, a przede wszystkim otrzymane wyniki wykazują jednoznacznie, że kierunek obranych badań jest zdecydowanie rozwojowy, a dalsze prace uzasadnione.

Planowana jest dalsza zaawansowana analiza sieciowa, ze szczególnym uwzględnieniem detekcji społeczności. Biorąc pod uwagę fakt, że mimo stosunkowo dużej liczby komponentów, detekcja największego z nich wykazała, że zawiera ponad 90% wszystkich węzłów, naturalnym wyborem jest analiza największego komponentu spójnego, jako reprezentatywnego dla całego grafu. Analiza społeczności może umożliwić detekcję kluczowych węzłów i krawędzi, co w dalszej kolejności pozwoli zdefiniować wzorce zachowań konsumentów oraz umożliwi ich predykcję.

**Autorzy:** mgr inż. Dominika Dudziak-Gajowiak, dr hab. inż. Krzysztof Juszczyzyn, Politechnika Wrocławska, Wydział Informatyki i Telekomunikacji, Katedra Informatyki i Inżynierii Systemów, E-mail: dominika.dudziak-gajowiak@pwr.edu.pl, krzysztof.juszczyzyn@pwr.edu.pl.

### LITERATURA

- [1] J. Kleinberg, J. The convergence of social and technological networks. *Communications of the ACM* Vol. 51, No.11, 66-72, 2008.
- [2] Onnela J.P., et al. Structure and tie strengths in mobile communication networks, *Proceedings of the National Academy of Sciences* 18, 7332-7336, 2007.
- [3] Mureddu M., Facchini A., Scala A., Guido Caldarelli G., Damiano A., A Complex Network Approach for the Estimation of the Energy Demand of Electric Mobility, *Scientific Reports* (2018), 8:268, DOI:10.1038/s41598-017-17838-5
- [4] Rosas-Casals M., Power Grids as Complex Networks. *Topology and Fragility, Complexity in Engineering* (2010), DOI 10.1109/COMPENG.2010.23
- [5] Kyriakos C., Chatzidimitriou N., Vavliakis L., Symeonidis A., Redefining the market power of small-scale electricity consumers through Consumer Social Networks, *IEEE 10th International Conference on e-Business Engineering* (2013), DOI 10.1109/ICEBE.2013.4
- [6] Stoyanow A., Energy Complex of a Municipality on the Example of Luleå (Sweden), *E3S Web of Conferences* (2019) DOI 10.1051/e3sconf/201914003005
- [7] G. Caldarelli, A. Vespignani, *Large Scale Structure and Dynamics of Complex Networks: From Information Technology to Finance and Natural Science*, World Scientific, USA, 2007.
- [8] T. Gross, H. Sayama (Eds.): *Adaptive networks: Theory, models and applications*, Springer: Complexity, Springer-Verlag, Berlin-Heidelberg, 2009.
- [9] National Renewable Energy Laboratory. (2022). BUTTER-E - Energy Consumption Data for the BUTTER Empirical Deep Learning Dataset [data set]. Retrieved from <https://dx.doi.org/10.25984/2329316>.
- [10] Blondel V., Guillaume J., Lambiotte R., *Mech E* (2008) Fast unfolding of communities in large networks. *J Stat Mech: Theory Exp* 2008:P10008.
- [11] Jacomy M, Venturini T, Heymann S, Bastian M (2014) ForceAtlas2, a Continuous Graph Layout Algorithm for Handy Network Visualization Designed for the Gephi Software. *PLoS ONE* 9(6): e98679. <https://doi.org/10.1371/journal.pone.0098679>
- [12] Kobourov S., (2012), Spring Embedders and Force-Directed Graph Drawing Algorithms, arXiv:1201.3011, Bibcode:2012arXiv1201.3011K.
- [13] Barrat, A., et al. (2004). The architecture of complex weighted networks. *Proceedings of the National Academy of Sciences of the United States of America*. 101 (11): 3747–3752.
- [14] Yingxu, W., et al. (2024) Distribution based Spiking Graph Networks for Domain Adaptation, 38th Conference on Neural Information Processing Systems (NeurIPS 2024).
- [15] Presekal, A., et al. (2023), Attack Graph Model for Cyber-Physical Power Systems Using Hybrid Deep Learning, *IEEE Transactions on Smart Grid*, vol. 14, no. 5, pp. 4007-4020, Sept. 2023, doi: 10.1109/TSG.2023.3237011.
- [16] Ruichu, C., et al. (2024), Graph domain adaptation: A generative view. *ACM Transactions on Knowledge Discovery from Data*, 18(3): 1–24, 2024.