

Elektrotechnika

Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne

AUTOREFERAT ROZPRAWA DOKTORSKA

Detekcja pracy wyspowej rozproszonych źródeł energii z wykorzystaniem metod estymacji fazorów i sieci neuronowych

Autor: Mohammad Abu Sarhan

Promotor rozprawy: dr hab. inż. Andrzej Bień, prof. uczelni Promotor pomocniczy: dr inż. Szymon Barczentewicz

> Praca wykonana: Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie

> > Kraków, 2025

Detekcja pracy wyspowej rozproszonych źródeł energii z wykorzystaniem metod estymacji fazorów i sieci neuronowych

Mohammad Abu Sarhan

1. Streszczenie

Techniki zabezpieczeń w klasycznych systemach elektroenergetycznych tworzone są przy założeniu, że w przypadku wystąpienia jakichkolwiek nietypowych lub niepożądanych okoliczności, części dotknięte tym anormalnym stanem zostaną odizolowane od całej sieci elektroenergetycznej. Alternatywą są systemy rozproszone, w których jedno ze źródeł w mikrosieci pozwala na pracę wyspową układu. Wykrywanie pracy wyspowej jest kluczowym procesem, który należy przeprowadzić, aby zapewnić niezawodność i bezpieczeństwo sieci dystrybucyjnych w kontekście integracji źródeł rozproszonych.

W badaniu przedstawiono nowe podejście do detekcji pracy wyspowej poprzez integrację danych synchrofazorowych z siecią neuronową (SSN). Podejście to wykorzystuje dane pozyskiwane z PMU, tj. napięcie, częstotliwość napięcia i szybkość zmiany częstotliwości napięcia (ROCOF), które są następnie wprowadzane do klasyfikatora SSN. Wykorzystując obszerny zbiór danych składający się z ponad stu tysięcy obserwacji zarówno w scenariuszu wyspowym, jak i scenariuszu pracy synchronicznej, przeprowadzono badania na kilku typach falowników, zgodnie z wymaganiami określonymi w normie PN-EN 62116. Eksperymenty przeprowadzono w trzech różnych laboratoriach doświadczalnych, gdzie dane i wyniki analizowano przy użyciu MATLAB-a i LabVIEW. Wyniki wykazują niezwykłą skuteczność detekcji na poziomie 99% dokładność uczenia na poziomie 99,3% i krótki czas reakcji na wykrywanie na poziomie 0.18 s. W opracowaniu przedstawiono pragmatyczne rozwiązanie problemów wynikających z pracy wyspowej w sieciach elektroenergetycznych, poprawiając tym samym niezawodność i bezpieczeństwo systemu.

2. Motywacja

Rosnaca ilość źródeł rozproszonych w nowoczesnych sieciach elektroenergetycznych znacząco zmieniła dynamikę ich działania, wprowadzając nowe wyzwania w zakresie ochrony, sterowania i stabilności. W tradycyjnych systemach elektroenergetycznych, istnieją dobrze ugruntowane algorytmy ochronne umożliwiające skuteczne przeciwdziałanie różnym awariom. W przypadku mikrosieci wraz ze źródłami rozproszonymi pojawiają się dodatkowe złożoności i konieczność wykorzystywania bardziej zaawansowanych metod detekcji zdarzeń. Jednym z kluczowych wyzwań w tym kontekście jest wykrywanie pracy wyspowej, czyli identyfikacja sytuacji, w których część sieci zasilana przez lokalne źródła rozproszone zostaje odłączona od głównej sieci elektroenergetycznej, ale nadal pracuje autonomicznie. Brak szybkiej i dokładnej detekcji wyspowej może prowadzić do zagrożeń bezpieczeństwa, pogorszenia jakości energii elektrycznej, uszkodzeń urządzeń oraz destabilizacji sieci. Dlatego rozwój skutecznych, szybkich i niezawodnych metod wykrywania pracy wyspowej jest kluczowy dla zapewnienia bezpieczeństwa i stabilności nowoczesnych systemów dystrybucyjnych.

Jednym z głównych problemów związanych z wykrywaniem pracy wyspowej są różnorodne charakterystyki źródeł DG, które wpływają na sposób manifestowania się tego zjawiska w systemie. Różne typy jednostek generacji rozproszonej, takie jak systemy fotowoltaiczne (PV) i generatory synchroniczne, wykazują odmienne zachowania elektryczne podczas pracy wyspowej. Generatory synchroniczne, dzięki swojej naturalnej inercji i automatycznemu regulatorowi napięcia (AVR), mogą utrzymywać stabilność napięcia, co może ukryć wystąpienie pracy wyspowej i utrudniać jej detekcję. Z kolei falowniki PV, które są w pełni sterowane elektronicznie i nie posiadają inercji, są bardziej podatne na wahania napięcia i częstotliwości, co umożliwia szybsze wykrywanie pracy wyspowej. Te różnice w odpowiedzi systemu utrudniają opracowanie uniwersalnych metod detekcji, ponieważ konwencjonalne techniki dostosowane do konkretnych typów DG mogą nie być skuteczne w różnych konfiguracjach systemu.

Dodatkowo, istniejące metody wykrywania pracy wyspowej mają istotne ograniczenia, które utrudniają ich szerokie zastosowanie. W przypadku metod pasywnych, wykorzystujących parametry sieci, takie jak napięcie, częstotliwość i tempo zmian częstotliwości (ROCOF),

zdarzenia wyspowe mogą pozostać niewykryte dla pewnych zakresów obserwowanych parametrów. Obszar w którym metoda pasywna nie jest w stanie wykryć pracy wyspowej nazywany jest obszarem NDZ. Metody aktywne, które wprowadzają zakłócenia do systemu w celu wywołania odpowiedzi wykrywalnej, mogą negatywnie wpływać na jakość energii i nie zawsze nadają się do wszystkich warunków operacyjnych. Metody oparte na falownikach są zazwyczaj dostosowane do konkretnej strategii sterowania każdego falownika i mogą nie działać efektywnie w systemach z wieloma źródłami rozproszonymi o różnych charakterystykach. Ograniczenia te podkreślają potrzebę bardziej elastycznego i skalowalnego podejścia, które pozostaje skuteczne niezależnie od liczby, typu i konfiguracji źródeł rozproszonych obecnych w mikrosieci.

Rosnąca rola odnawialnych źródeł energii, zwłaszcza systemów opartych na falownikach, takich jak fotowoltaika i energetyka wiatrowa, dodatkowo komplikuje detekcję pracy wyspowej. W miarę przechodzenia tradycyjnych systemów elektroenergetycznych na większe wykorzystanie odnawialnych źródeł energii, rola maszyn synchronicznych stopniowo maleje, a generacja oparta na falownikach staje się coraz bardziej dominująca. Ta zmiana wprowadza nowe wyzwania, ponieważ sieci zdominowane przez falowniki zachowują się inaczej niż konwencjonalne systemy, wymagając innowacyjnych strategii detekcji, które uwzględniają ich unikalne właściwości. Jednocześnie zdolność falowników do naśladowania zachowania sieci w określonych strategiach sterowania może opóźniać wykrywanie pracy wyspowej, zwiększając ryzyko długotrwałej niedetekcji.

W celu sprostania tym wyzwaniom, zaawansowane techniki przetwarzania sygnałów oraz sztuczna inteligencja otwierają nowe możliwości poprawy wykrywania pracy wyspowej. Nowoczesne podejścia wykorzystujące obliczanie fazora oraz uczenie maszynowe oferują obiecujące rozwiązania, które mogą zwiększyć dokładność detekcji i skrócić czas reakcji. Analizując duże zbiory danych zawierające różnorodne scenariusze wyspowe i niewyspowe, metody oparte na AI mogą skuteczniej rozróżniać pracę wyspową od innych zakłóceń niż tradycyjne techniki. Integracja przetwarzania danych w czasie rzeczywistym dodatkowo wzmacnia możliwości wykrywania, zapewniając szybkie wykrywanie pracy wyspowej bez negatywnego wpływu na stabilność systemu.

W obliczu rosnącej złożoności nowoczesnych sieci elektroenergetycznych konieczne jest opracowanie uniwersalnych, niezawodnych i skalowalnych metod detekcji pracy wyspowej, które

mogą skutecznie działać w różnych konfiguracjach systemu. Badania w tej dziedzinie powinny koncentrować się na opracowywaniu metod, które są nie tylko dokładne i szybkie, ale także dostosowane do przyszłych architektur sieci, w których proporcje maszyn synchronicznych i generacji opartej na falownikach będą się nadal zmieniać. Dzięki wykorzystaniu nowoczesnych technik przetwarzania sygnałów oraz sztucznej inteligencji możliwe jest opracowanie systemów detekcji, które zwiększają odporność sieci rozproszonych, zapewniając niezawodną i bezpieczną pracę w obliczu dynamicznych zmian w sektorze energetycznym.

3. Najważniejsze wyniki pracy

Do budowy badanego systemu dystrybucyjnego przeprowadzono eksperymenty w trzech różnych laboratoriach. W laboratorium Reflex główna sieć jest połączona z falownikiem PV, falownikiem generatora synchronicznego, obciążeniem liniowym i nieliniowym, a pomiary zostały wykonane przy użyciu platformy National Instruments NI6040E. W laboratorium Centrum Energii główna sieć to system zasilany przez regeneracyjny symulator sieci Chroma 61815, który jest połączony z symulatorem paneli fotowoltaicznych podłączonym do testowanego falownika oraz regulowanego obciążenia RLC. Pomiary zostały przeprowadzone przy użyciu sprzętu pomiarowego National Instruments Crio-9024. W laboratorium Dynamicznych Systemów Energetycznych główna sieć to symulowana równoważna sieć w czasie rzeczywistym za pomocą Real-Time Digital Simulator, który jest połączony z trójfazowym falownikiem o mocy 10 kW. Pomiary zostały zarejestrowane za pomocą czujników prądu i napięcia oraz oprogramowania RCAD.

Wymagane oszacowanie pomiaru fazorowego (PMU) oraz sztuczna sieć neuronowa (ANN) zostały zaprogramowane w oprogramowaniu MATLAB. Napięcie falownika zostało zarejestrowane podczas niezamierzonego zdarzenia wyspowego dla różnych scenariuszy dopasowania mocy między falownikiem a obciążeniem, a następnie zastosowano PMU do ekstrakcji wymaganych cech (napięcia skutecznego, częstotliwości i ROCOF), zgodnie z rysunkiem 1 (a), (b), (c) i (d), które są niezbędne dla klasyfikatora ANN do określenia warunków wyspowych i niewyspowych.



Rysunek 1 Napięcie fazorowe falownika, częstotliwość i ROCOF podczas niezamierzonego wyspowania dla (a) scenariusza 1, (b) scenariusza 2, (c) scenariusza 3 i (d) scenariusza 4

Zbiór danych wykorzystany do procesu treningu sztucznej sieci neuronowej (ANN) zawiera setki tysięcy obserwacji zdarzeń wyspowych i niewyspowych. Zbiór danych treningowych jest macierzą składającą się z setek tysięcy wierszy i 4 kolumn. Wszystkie wiersze reprezentują różne sytuacje i przypadki zdarzeń zarówno zdarzenia, w których zachodzi jak i nie zachodzi praca wyspowa. Pierwsze trzy kolumny zawierają wartości predyktorów (parametrów wejściowych), a mianowicie napięcie skuteczne, częstotliwość oraz ROCOF, natomiast ostatnia

kolumna przedstawia odpowiedź lub wynik. Wynik przyjmuje wartość 0, co oznacza, że system nie znajduję się w stanie pracy wyspowej, lub 1, co wskazuje, że system jest w stanie nieintencjonalnej pracy wyspowej, jak zilustrowano w Tabeli 1.

Case no.	Phasor Voltage [V]	Frequency [Hz]	ROCOF [Hz/s]	Outcome
1	325.6311	50.00336	-0.00113	0
1061	334.2130	53.76710	137.4227	1
1253	325.4371	50.00054	0.003009	0
2830	332.5613	55.03513	116.613	1
2997	325.591	50.00065	0.0169	0
6159	310.393	57.02548	46.9333	1
6422	325.721	50.00056	0.00616	0
7730	297.354	49.47087	-12.8572	1
8310	325.724	50.00045	0.01449	0
9932	320.047	45.61211	-1.3501	1
10356	325.64	50.00066	0.01228	0
12577	207.391	53.43756	26.9291	1
13769	325.547	49.99661	0.06308	0
13924	329.051	50.29849	5.65685	1
57414	325.607	50.00061	0.00341	0
60097	307.08	55.82833	179.016	1
60374	325.753	50.00058	-0.00029	0
63968	333.0892	52.175534	72.42099	1
70395	325.6145	50.000623	-0.0019	0
78070	319.2818	49.976431	15.60329	1
79650	325.6507	50.00045	0.001316	0
80107	298.9276	50.535499	-18.7912	1
83909	325.642	49.999962	0.033554	0
84713	324.5224	52.736807	82.71616	1
86945	325.684	50.00066	-0.00269	0
89237	340.4295	53.860815	160.1389	1
91553	325.6295	50.000389	-0.00883	0
92546	322.4447	48.97164	7.26551	1
95930	325.5419	49.99986	0.02075	0
97584	325.8385	47.188339	-22.4117	1
100239	325.6212	50.000649	0.028159	0
102484	317.3278	47.318808	-134.54	1
104737	325.5797	50.001108	0.005606	0
107144	343.9238	53.149936	197.3891	1
107533	325.6944	50.000658	-0.0235	0
108851	347.2253	52.278491	176.2884	1
110531	325.5919	49.999875	0.00946	0
114107	329.2767	54.303263	29.55277	1
114349	325.5534	50.000508	0.021124	0
115783	326.3335	54.060305	100.0834	1
164998	325.5046	50.000121	-0.03925	0
175783	318.697	50.174623	2.742095	1
187882	325.7082	50.000873	0.02608	0

Tabela 1. Przykładowe próbki zbioru danych użytego do trenowania klasyfikatora.

|--|

Wytrenowana sztuczna sieć neuronowa (ANN) to wielowarstwowa, jednokierunkowa sieć neuronowa (FNN) składająca się z trzech warstw, z których każda ma rozmiar dziesięciu neuronów. Parametry specyfikacji wytrenowanej sieci ANN przedstawiono w Tabeli 2.

Tabela 2. Specyfikacja parametrów sieci ANN.

Parameter	Value
No. of fully linked layers	3
First layer size	10
Second layer size	10
Third layer size	10
Activation Function	Rectified liner Unit
Standardize data	Yes

Skuteczność modelu klasyfikacyjnego jest oceniana na podstawie parametrów wydajności, takich jak czułość, swoistość, wartość predykcyjna dodatnia (PPV), wartość predykcyjna ujemna (NPV) oraz dokładność klasyfikacji. Zgodnie z wcześniej przedstawioną tablicy pomyłek, wartości parametrów opracowanego modelu ANN zostały przedstawione w Tabeli 3.

Parameter	Percentage
Sensitivity	99.5%
Specificity	99.27%
Positive predictive value	98.31%
Negative predictive value	99.78%
Accuracy	99.34%

Tabela 3. Wartości ograniczeń modelu ANN.

Model został zweryfikowany przy użyciu metody holdout z 25% danych przeznaczonych do walidacji. Dokładność modelu podczas treningu i testowania wyniosła odpowiednio 99,3% i 99%, co przedstawiono w Tabeli 4.

Tabela 4. Wyniki modelu ANN.

Accuracy (Validation)	Accuracy (Test)	Prediction Speed (obs/sec)	Time of Training (sec)
99.3%	99%	901516	130.6

Proponowana metoda została porównana z kilkoma istniejącymi technikami, takimi jak Naïve Bayes, uogólniony model liniowy regresji logistycznej oraz analiza dyskryminacji liniowej. Porównanie graficzne dokładności proponowanego modelu z innymi klasyfikatorami przedstawiono na Rysunku 2.



Rysunek 2. Porównanie dokładności między proponowanym modelem a innymi metodami.

Falownik DG musi zidentyfikować i odłączyć zasilanie podczas nieintencjonalnej pracy wyspowej w ciągu 2 sekund, zgodnie z normami IEEE. Scenariusz, który był brany pod uwagę podczas rejestrowania czasu detekcji badanych falowników i proponowanego modelu, to sytuacja, w której istniała równowaga mocy pomiędzy stroną falownika a stroną obciążenia, ponieważ ten scenariusz prowadzi do większej strefy niedetekcji w porównaniu do poprzednich przypadków, co wymaga dodatkowego czasu dla falowników na identyfikację zdarzenia pracy wyspowej. Tabela 5 przedstawia porównanie czasów detekcji między zaprojektowanym modelem a ocenianymi falownikami.

Detection Time (Seconds)				
Tested	Inverters	Proposed Model		
Inv.1	0.66	0.20		
Inv.2	0.43	0.25		
Inv.3	0.26	0.18		
Inv.4	1.03	0.15		
Inv.5	6.47	0.18		
Inv.6	0.74	0.20		
Inv.7	6.24	0.39		
Inv.8	0.22	0.12		
Inv.9	0.45	0.10		
Inv.10	1.51	0.10		
Inv.11	1.09	0.12		
Inv.12	0.14	0.20		
Inv.13	0.17	0.16		
Inv.14	0.02	0.16		
Inv.15	0.19	0.11		
Inv.16	0.83	0.31		
Inv.17	0.12	0.13		
Inv.18	0.10	0.18		
Inv.19	0.61	0.42		
Inv.20	0.32	0.15		
Inv. 21	0.22	0.18		
Inv.22	0.20	0.17		
Inv.23	0.55	0.12		
Inv.24	0.27	0.17		
Inv.25	0.35	0.17		
Inv.26	0.63	0.18		
Inv.27	0.87	0.18		

Tabela 5. Porównanie czasu odpowiedzi między proponowanym modelem a testowanymi falownikami.

Jak widać z Tabeli 5, falowniki 5 i 6 nie wykryły incydentu wyspowania w ciągu 2 sekund, podczas gdy inne testowane falowniki były w stanie rozpoznać incydent wyspowania w dopuszczalnym czasie. Proponowany model spełnia wymagania stawiane metodom detekcji pracy wyspowej w kontekście czasu detekcji. Proponowany model był szybszy w wykrywaniu pracy wyspowej niż algorytmy zaimplementowane w testowanych falownikach w większości przypadków. Tylko falowniki 12, 14, 17 i 18 były nieznacznie szybsze od proponowanej metody.

4. Podsumowanie

Aby skutecznie i efektywnie zidentyfikować wystąpienie pracy wyspowej, w niniejszym badaniu opracowano metodę hybrydową, która łączy zarówno metodę pomiaru synchrofazora (PMU), jak i sztuczną sieć neuronową (ANN). Technika detekcji wyspowania wykorzystująca PMU-ANN jest skuteczną metodą rozróżniania między zdarzeniami wyspowania a zdarzeniami braku wyspowania w systemach elektroenergetycznych. Podejście to osiągnęło doskonałe wyniki podczas szczegółowych testów laboratoryjnych, wykorzystując możliwości jednostek pomiaru fazora (PMU) do ekstrakcji istotnych cech, takich jak napięcie skuteczne, częstotliwość napięcia oraz tempo zmiany częstotliwości napięcia (ROCOF), a także skuteczność sztucznych sieci neuronowych (ANN) jako algorytmu klasyfikacyjnego. Skrupulatna ocena, obejmująca testowanie na kilku rodzajach falowników zgodnie z wytycznymi procedury PN-EN 62116, dała niezwykłe wyniki, z dokładnością testu na poziomie 99,05% i dokładnością treningu na poziomie 99,34%. Ponadto, odporność i trwałość zaprezentowanej metody zostały wykazane przez wykorzystanie dużego zbioru danych zawierającego ponad 100 tysięcy próbek obejmujących zarówno zdarzenia pracy wyspowej, jak i pracy synchronicznej, które służyły do treningu i oceny zaproponowanego algorytmu. Niniejsze badania stanowią ważny wkład w dziedzinę detekcji pracy wyspowej, dostarczając prostą i łatwo implementowalną technikę, którą można łatwo wdrożyć w różnych zastosowaniach sieci energetycznych. Ta strategia oferuje możliwość znacznego zwiększenia bezpieczeństwa i efektywności globalnych sieci przesyłowych i dystrybucyjnych energii, poprzez zwiększenie zdolności do dokładniejszego i efektywniejszego wykrywania pracy wyspowej. Ma potencjał, by poprawić ogólną efektywność, bezpieczeństwo i niezawodność współczesnych systemów elektroenergetycznych.

5. Wykaz publikacji i osiągnięć autora

Published Journal Papers

- Lerch, Tomasz, Szymon Barczentewicz, Mohammad Abu Sarhan, Zhiwang Feng, and Graeme Burt. "Grid tie converters aided rapid grid voltage fluctuation compensation with power hardware-in-the-Loop experimental validation." *e+ i Elektrotechnik und Informationstechnik* (2025): 1-9. (Q4, 20 Points)
- Sarhan, Mohammad Abu, Szymon Barczentewicz, and Tomasz Lerch. "Hybrid islanding detection method using PMU-ANN approach for inverter-based distributed generation systems." *IET Renewable Power Generation* 18 (2024): 4453-4464. (Q2, 100 Points)
- Abu Sarhan, Mohammad, Andrzej Bien, and Szymon Barczentewicz. "Use of analytical hierarchy process for selecting and prioritizing islanding detection methods in power grids." *International Journal of Electrical & Computer Engineering (2088-8708)* 14, no. 3 (2024). (Q2, 70 Points)
- 4. Abu Sarhan, Mohammad. "An extensive review and analysis of islanding detection techniques in DG systems connected to power grids." *Energies* 16, no. 9 (2023): 3678. (Q1, 140 Points)
- Sarhan, Mohammad Abu, Andrzej Bień, Szymon Barczentewicz, and Rana Hassan. "A review of electricity and renewable energy sectors status and prospect in Jordan." *Przeglad Elektrotechniczny* 97, no. 9 (2021). (Q4, 70 Points)
- Hassan, Rana Muneeb, Andrzej Bien, Szymon Barczentewicz, and Mohammad Abu Sarhan. "Energy Sector of Pakistan–A Review." *Przeglad Elektrotechniczny* 97, no. 10 (2021). (Q4, 70 Points)

Published Conference Papers

- Sarhan, Mohammad Abu, Andrzej Bien, Szymon Barczentewicz, and Rana Hassan. "Global Maximum Power Point Tracking (GMPPT) Control Method of Solar Photovoltaic System under Partially Shaded Conditions." In 2022 8th International Conference on Automation, Robotics and Applications (ICARA), pp. 209-216. IEEE, 2022. (20 Points)
- Sarhan, Mohammad Abu, Andrzej Bien, and Szymon Barczentewicz. "Experimental study of power definitions in non-sinusoidal condition." In 2022 5th International Conference on Electronics and Electrical Engineering Technology (EEET), pp. 126-131. IEEE, 2022. (20 Points)
- Sarhan, Mohammad Abu, Szymon Barczentewicz, and Andrzej Bien. " Dynamic voltages and currents in the microgrids while unintentional islanding." In KNER: I Konferencja Naukowa Energetyki Rozproszonej KNER, 2023.