

Wrocław 20.06.2023

dr inż. Vishnu Suresh
Politechnika Wrocławska
Wydział Elektryczny
Katedra Podstaw Elektrotechniki I Elektrotechnologii,
ul. Wybrzeże Wyspiańskiego 27, 50-370 Wrocław

*Autoreferat w języku polskim
przedstawiający opis dorobku i osiągnięć naukowych
dr inż. Vishnu Suresh*

1. Imiona i nazwisko

Vishnu Sidaarth Suresh

2. Dyplomy i dziedziny

Stopień doktora nadany w dziedzinie nauk inżynieryjno technicznych w dyscyplinie naukowej automatyka, elektronika i elektrotechnika.

Politechnika Wroclawska, Wydział Elektryczny.

Rozprawa pt.: „Microgrid energy management systems with hybrid optimizers, embedded deep learning forecasters, and EV charging stations”.

Promotor pracy: dr hab. inż. Przemysław Janik.

Recenzenci pracy: prof. Ing. Radomir Gono oraz prof. dr hab. inż. Janusz Mindykowski.

Data nadania stopnia: 27.09.2021

Dyplom ukończenia studiów magisterskich.

Politechnika Wroclawska, Wydział Elektryczny.

Kierunek Elektrotechnika, specjalność Control in Electrical Power Engineering.

Temat pracy: „Methods of magnetizing inrush recognition in power transformers including using neural network”.

Promotor pracy: prof. dr hab. inż. Waldemar Rebizant.

Rok ukończenia studiów: 2016.

Dyplom ukończenia studiów inżynierskich.

University of Petroleum and Energy Studies, India, Katedra Elektrotechniki i Energetyki.

Kierunek Elektrotechnika.

Temat pracy: „Power system modelling and Analysis in ETAP”.

Rok ukończenia studiów: 2014

3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych:

15.12.2021 – nadal: zatrudnienie na stanowisku adiunkta, Katedra Podstaw Elektrotechniki i Elektrotechnologii, Wydział Elektryczny, Politechnika Wroclawska.

01.01.2022 – 31.12.2022: zatrudnienie jako starszy inżynier elektryk (8,34 godziny na tydzień), E-Phant (startup sfinansowany w Brandenburgische Technische Universität Cottbus-Senftenberg, Niemcy).

01.10.2021 – 15.12.2021: zatrudnienie na stanowisku asystenta, Katedra Podstaw Elektrotechniki i Elektrotechnologii, Wydział Elektryczny, Politechnika Wrocławska.

01.06.2021 – 02.10.2021: zatrudniony na stanowisku Associate Scientist w dziale Embedded Power Systems w Hitachi ABB Power Grids, Kraków.

30.06.2022 – 30.06.2025: zatrudnienie na stanowisku adiunkta (wizytujący) do nauczania i badań w School of Electrical Engineering (SELECT) w Vellore Institute of Technology, Chennai, Indie.

4. Omówienie osiągnięć, o których mowa w art. 219 ust. 1 pkt. 2 Ustawy.

Podstawą wniosku habilitacyjnego były osiągnięcia przedstawione w serii powiązanych tematycznie publikacji pt. **"Sztuczna inteligencja/uczenie maszynowe (AI/ML) dla prognozowania i inteligentnego zarządzania rozproszonymi zasobami energii"**.

Większość prac wchodzących w skład tej serii powstała w wyniku współpracy naukowej z innymi ośrodkami badawczymi podczas realizacji projektów badawczych. Dlatego w poniższym opisie zostały wskazane najważniejsze obszary, które są wynikiem pracy Habilitanta w poszczególnych rozprawach. Dodatkowo, w celu jednoznacznego określenia wkładu w powstanie publikacji, wykorzystano rekomendacje wydawnictwa Elsevier (oświadczenie autora CRediT), podając zarówno wkład Habilitanta, jak i poszczególnych współautorów. Ten wkład został opisany w wykazie osiągnięć naukowych przedstawionym w niniejszym wniosku.

W wykazie publikacji zaliczonych do cyklu oraz dodatkowych publikacji wynikających z międzynarodowej współpracy Habilitanta zostały uwzględnione:

- [1] **Vishnu S. Suresh**, Fachrizal F. Aksan, Przemysław Janik, Tomasz Sikorski, B. Sri Revathi. *Probabilistic LSTM-Autoencoder based hour-ahead solar power forecasting model for intra-day electricity market participation: A Polish case study.* IEEE Access (MNiSW: 100 pkt., IF: 3,476), 2022, vol. 10, s. 110628-110638.

Wkład habilitatora obejmuje: Konceptualizacja idei polegającej na prognozowaniu energii wyjściowej z paneli fotowoltaicznych w celu poradzenia sobie z ich nieprzewidywalnością. Metodologia zajmująca się modelami głębokiego uczenia, które zostały wybrane do realizacji dokładnych prognoz. Oprogramowanie obejmujące programowanie wybranych modeli w pythonie. Walidacja i analiza formalna, która obejmuje wykreślanie wyników i ustalanie metryk dokładności w celu oceny wydajności modelu prognostycznego. Pisanie oryginalnego manuskryptu i odpowiadanie na komentarze recenzentów. Na koniec wizualizacja rycin użytych w artykule. Wnioskodawca był również autorem korespondencyjnym.

- [2] **Vishnu S. Suresh**, Przemysław Janik, Michał M. Jasiński, Josep M. Guerrero, Zbigniew Leonowicz. *Microgrid energy management using metaheuristic optimization algorithms.*

Applied Soft Computing (MNiSW: 200 pkt., IF: 8,263). 2023, vol. 134, art. 109981, s. 1-18.

Wkład habilitatora obejmuje: Konceptualizacja polegająca na wykorzystaniu zoptymalizowanych inteligentnych algorytmów optymalizacyjnych do dystrybucji rozproszonych zasobów energii w celu określenia minimalnych kosztów operacyjnych w mikro sieci. Metodologia zajmująca się wykorzystaniem metaheurystycznych algorytmów optymalizacyjnych. Oprogramowanie obejmujące programowanie wybranych modeli w matlabie. Walidacja i analiza formalna obejmująca wykreślanie wyników, optymalizację hiperparametryczną algorytmu optymalizacyjnego oraz ocenę wydajności wszystkich badanych podejść. Pisanie oryginalnego manuskryptu i odpowiadanie na komentarze recenzentów. Na koniec wizualizacja rycin użytych w artykule. Wnioskodawca był również autorem korespondencyjnym.

- [3] **Vishnu S. Suresh**, Michał M. Jasiński, Zbigniew Leonowicz, Dominika N. Kaczorowska, Jayachandranath Jithendranath, Hemachandra K. Reddy.
Political-optimizer-based energy-management system for microgrids.
Electronics (MNiSW: 100 pkt., IF: 2,690). 2021, vol. 10, nr 24, art. 3119, s. 1-18.

Wkład habilitatora obejmuje: Konceptualizacja polegająca na wykorzystaniu inteligentnych algorytmów optymalizacyjnych do rozdysponowania rozproszonych zasobów energii w celu określenia minimalnych kosztów operacyjnych w mikro sieci. Metodologia zajmująca się wykorzystaniem metaheurystycznych algorytmów optymalizacyjnych. W tym przypadku zbadano nowo opracowany Optymalizator Polityczny. Oprogramowanie obejmujące programowanie wybranych modeli w matlabie. Analiza formalna obejmująca wykreślenie wyników i ocenę wydajności wszystkich badanych podejść. Pisanie oryginalnego manuskryptu. Na koniec wizualizacja rycin użytych w artykule. Wnioskodawca był również autorem korespondencyjnym.

- [4] Polamarasetty P. Kumar, Vishnu S. Suresh, Michał M. Jasiński, Zbigniew Leonowicz.
Off-grid rural electrification in India using renewable energy resources and different battery technologies with a dynamic differential annealed optimization.
Energies (MNiSW: 140 pkt., IF: 3,252). 2021, vol. 14, nr 18, art. 5866, s. 1-21

Wkład habilitatora obejmuje: Badanie mające na celu znalezienie właściwych równań i modelowanie 3 modeli akumulatorów, którymi są akumulatory niklowo-żelazowe (Ni-Fe), litowo-jonowe (Li-Ion) i kwasowo-ołowiowe (LA). Udział w ustosunkowaniu się do części uwag recenzji. Zarządzanie zasobami w zakresie dostarczanych danych dla wytwórców energii odnawialnej oraz dostarczanie dodatkowej mocy obliczeniowej

poprzez przetwarzanie w chmurze. Na koniec wizualizacja rycin użytych w artykule. Wnioskodawca był również autorem korespondencyjnym.

- [5] Polamarasetty P. Kumar, Ramakrishna S. S. Nuvvula, Md. Alamgir. Hossain, SK. A. Shezan, **Vishnu S. Suresh**, Michał M. Jasiński, Radomír Goňo, Zbigniew Leonowicz. *Optimal operation of an integrated hybrid renewable energy system with demand-side management in a rural context.* Energies (MNiSW: 140 pkt., IF: 3,252). 2022, vol. 15, nr 14, art. 5176, s. 1-50.

Wkład habilitatora obejmuje: Kuracja danych polegająca na zebraniu danych z różnych źródeł, które obejmują zarówno generator, jak i obciążenia wykorzystywane w hybrydowym systemie energii odnawialnej. Kandydat był również zaangażowany w modelowanie przy podejmowaniu decyzji o zastosowanych wskaźnikach analizy kosztów, którymi są koszt bieżący netto i koszt cyklu życia. Kandydat był również autorem korespondencyjnym.

- [6] Fachrizal F. Aksan, Yang Li, **Vishnu S. Suresh**, Przemysław Janik *CNN-LSTM vs. LSTM-CNN to predict power flow direction: a case study of the high-voltage subnet of Northeast Germany.* Sensors (MNiSW: 100 pkt., IF: 3,847). 2023, vol. 23, nr 2, art. 901, s. 1-20.

Wkład habilitatora obejmuje: Oprogramowanie w zakresie programowania badanych modeli głębokiego uczenia w języku Python. Walidacja pod kątem sprawdzenia działania zaprogramowanych modeli. Analiza formalna pod kątem sprawdzenia solidności modelu poprzez jego kilkukrotne uruchomienie i analizę spójności wyników za pomocą testów statystycznych. Odpowiadanie na komentarze recenzentów. Opieka nad autorem wiodącym, ponieważ kandydat jest promotorem autora pomocniczym. Wreszcie, administracja projektem poprzez zorganizowanie finansów na publikację manuskryptu.

- [7] Fachrizal F. Aksan, Yang Li, **Vishnu S. Suresh**, Przemysław Janik *Multistep forecasting of power flow based on LSTM autoencoder: a study case in regional grid cluster proposal.* Energies (MNiSW: 140 pkt., IF: 3,2). 2023, vol. 16, nr 13, art. 5014, s. 1-20.

Wkład habilitatora obejmuje: Opiekę nad autorem prowadzącym, ponieważ kandydat jest promotorem pomocniczym autora. Transfer modelu LSTM Autoencoder ze względu na jego wysoką wydajność w zrozumieniu relacji czasowych w dostarczonych danych wejściowych. Wreszcie, administracja projektem poprzez zorganizowanie finansów na publikację manuskryptu.

- [8] Habib Kraiem, Aymen Flah, Naoui Mohamed, Mohamed H. B. Messaoud, Essam A. Al-Ammar, Ahmed Althobaiti, Abdullah Alhumaidi, Alotaibi, Michał M. Jasiński, **Vishnu S. Suresh**, Zbigniew Leonowicz, Elżbieta Jasińska.

Decreasing the battery recharge time if using a fuzzy based power management loop for an isolated micro-grid farm.

Sustainability (MNiSW: 100 pkt., IF: 3,889). 2022, vol. 14, nr 5, art. 2870, s. 1-21.

Wkład habilitatora obejmuje: metodologię obejmującą modelowanie autonomicznej mikro sieci. Badanie mające na celu zidentyfikowanie pętli zarządzania energią opartej na logice rozmytej jako odpowiedniej metody skracania czasu ładowania baterii spośród wielu innych dostępnych metod. Wreszcie pozyskanie finansowania.

- [9] Fachrizal F. Aksan, **Vishnu S. Suresh**, Przemysław Janik, Tomasz Sikorski
Load Forecasting for the Laser Metal Processing Industry Using VMD and Hybrid Deep Learning Models.

Energies (MNiSW: 140 pkt., IF: 3,2). 2023 vol. 16, nr. 14, art. 5381, s. 1-24.

Wkład habilitatora obejmuje: konceptualizacja w zakresie zaproponowania wykorzystania modeli głębokiego uczenia się do prognozowania zapotrzebowania na obciążenie fabryki, kuracja danych, która obejmowała czyszczenie i wstępne przetwarzanie danych. Analiza formalna pod kątem zrozumienia zapotrzebowania obciążenia fabryki w ciągu roku i kilku lat z wykorzystaniem narzędzi statystycznych. Habilitantka zaproponowała również metodologię wykorzystania dekompozycji w trybie wariacyjnym wraz z modelami hybrydowymi, takimi jak model CNN-GRU i CNN-LSTM. Wnioskodawca był również zaangażowany w oprogramowanie poprzez programowanie modeli, pisanie oryginalnego manuskryptu i pomoc w odpowiadaniu na uwagi recenzenta. Wreszcie, wnioskodawca był również zaangażowany w zarządzanie zasobami projektu, co obejmuje przetwarzanie danych i generowanie wizualizacji wyników.

- [10] Mohan Bharathidasan, Vairavasundaram Indragandhi, **Vishnu S. Suresh**, Michał M. Jasiński, Zbigniew Leonowicz.

A review on electric vehicle: technologies, energy trading, and cyber security.

Energy Reports (MNiSW: 100 pkt., IF: 4,937). 2022, vol. 8, s. 9662-9685.

Wkład habilitatora obejmuje: konceptualizację, metodologię, analizę formalną, badania, zasoby, napisanie oryginalnego manuskryptu, ustosunkowanie się do uwag odbiorcy oraz wizualizację części pracy przeglądowej dotyczącej technologii ładowania i handlu energią. Obejmuje to przegląd metod szybkiego ładowania, ładowania nocnego,

ładowania flash i ładowania trasy. Obejmuje to również przegląd wymiany baterii. Sekcja handlu energią dokonuje przeglądu metod taryfowych i handlu peer-to-peer.

Analiza cyklu publikacji oraz artykułów wskazanych jako dodatkowe pod względem wytycznych oceny wg MNiSW oraz wskaźnika Impact Factor

<i>Nr.</i>	<i>Nazwa czasopisma</i>	<i>Punkty wg MniSW</i>	<i>Impact factor</i>	<i>Rok publikacji</i>
[1]	IEEE Access	100	3,476	2022
[2]	Applied Soft Computing	200	8,263	2023
[3]	Electronics	100	2,690	2021
[4]	Energies	140	3,252	2021
[5]	Energies	140	3,252	2022
[6]	Sensors	100	3,847	2023
[7]	Energies	140	3,200	2023
[8]	Sustainability	100	3,889	2022
[9]	Energies	140	3,200	2023
[10]	Energy Reports	100	4,937	2022
-	Łącznie	1260	40,006	-

Wskaźniki bibliograficzne

Sumaryczny Impact Factor cyklu publikacji	40,006
Suma punktów MNiSW cyklu publikacji i prac dodatkowych	1260
Sumaryczny Impact Factor wszystkich publikacji po uzyskaniu st. doktora	40,006
H index wg bazy Web of Science Core Collection	8
H index wg bazy Scopus	8
H index wg bazy Google Scholar	11

Omówienie osiągnięć naukowych Habilitanta

W obecnej politycznej sytuacji istnieje rosnący nacisk na przyjęcie źródeł energii odnawialnej, zwłaszcza fotowoltaiki słonecznej. Europejski Zielony Ład wymaga dodania rocznie 21-22 GW mocy fotowoltaiki w celu redukcji emisji o 55%, a przy celu 60% redukcji konieczne jest dodanie kolejnych 5-10 GW. Wzrost mocy odnawialnej prowadzi do większego udziału tych źródeł na rynkach energii, a precyzyjne prognozowanie generacji energii odnawialnej staje się kluczowe. Prognozowanie energetyczne jest istotne dla operatorów elektrowni, operatorów sieci i handlowców energią, umożliwiając im optymalizację działań. Zapewnia to skuteczną integrację odnawialnych źródeł energii w sieci, optymalizację uczestnictwa w rynku energii elektrycznej, efektywne zarządzanie magazynowaniem energii i planowanie infrastruktury sieciowej [1].

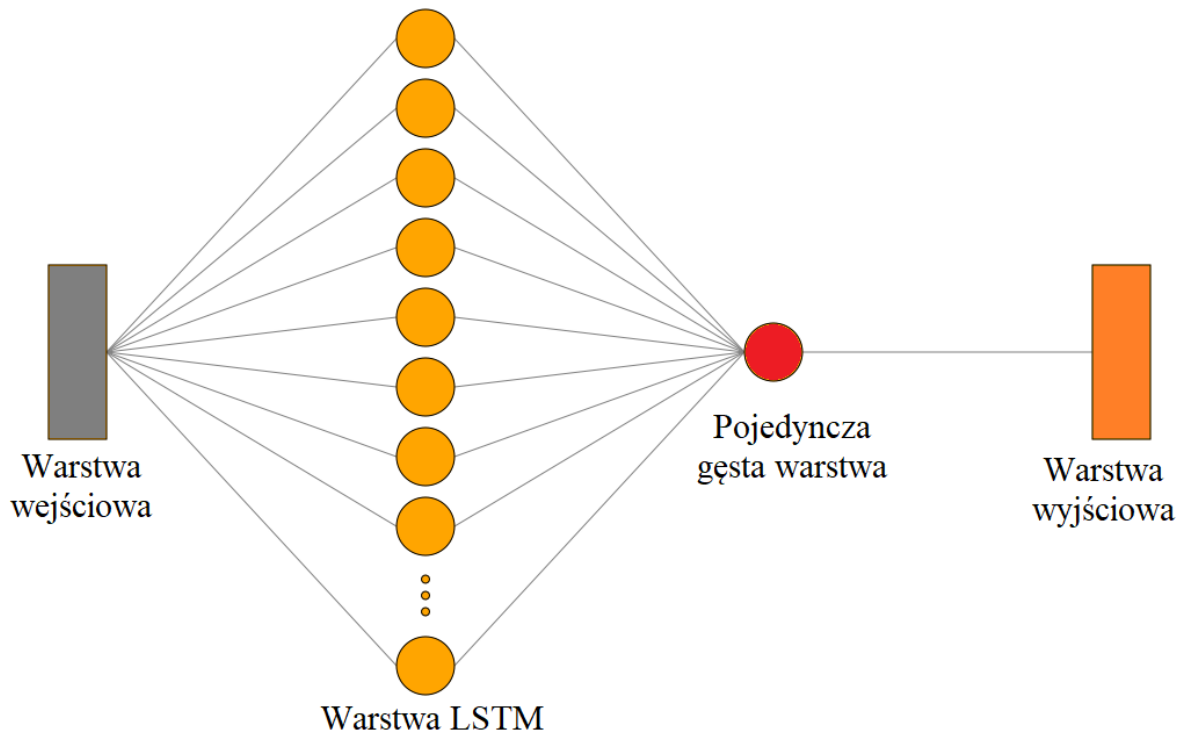
Opis osiągnięć podzielony jest na dwie główne części. Pierwszy dotyczył AI/ML do prognozowania, a drugi inteligentnego zarządzania rozproszonymi zasobami energii.

I. Sztuczna inteligencja/uczenie maszynowe (AI/ML) dla prognozowania.

W celu uzyskania modelu prognostycznego, który jest dokładny i solidny[1]. Rozważono 4 modele LSTM oparte na głębokim uczeniu się o różnych architekturach, którymi były model LSTM Vanilla, model dwukierunkowy LSTM, model LSTM Stacked i model LSTM Autoencoder. Modele są opisane w następujący sposób.

Struktura modelu jest przedstawiona na rysunku 1. Model podstawowy (Vanilla) to pojedynczy model warstwowy LSTM, który jest szybko trenowany i skutecznie ekstrahuje zależności czasowe występujące w danych wejściowych. Ten model, podobnie jak inne, zazwyczaj składa się z warstwy wejściowej, warstwy wyjściowej i pojedynczej warstwy sieci neuronowej. Najważniejszym aspektem każdego modelu opartego na głębokim uczeniu jest kształt danych wejściowych przekazywanych do sieci. W tym przypadku dane wejściowe mają trójwymiarowy kształt, składający się z liczby próbek, liczby kroków czasowych i liczby cech. Dane wyjściowe mają jednowymiarową strukturę, która jest prognozą docelową. Warstwa gęsta z jednym neuronem umożliwia odbiór danych wyjściowych w formie jednowymiarowym. Model podstawowy LSTM to prosty, ale efektywny model do prognozowania na podstawie sekwencji danych czasowych. Wykorzystuje jedną warstwę LSTM do analizy zależności między danymi wejściowymi, a następnie przekazuje wyniki do warstwy wyjściowej za pomocą warstwy gęstej. Ta struktura pozwala na skuteczne uczenie się i prognozowanie na podstawie wcześniejszych wzorców i zależności w danych.

Model bi-kierunkowej sieci LSTM pozwala na zrozumienie sekwencyjnych wzorców w danych wejściowych, ucząc się zarówno z kierunku przeszłego, jak i przyszłego. Osiąga to poprzez przetwarzanie wektora wejściowego w obu kierunkach - w przód i wstecz, co pozwala na uchwycenie zależności czasowych w danych. Istotną cechą tego modelu jest również jego zdolność do obsługi sekwencji o zmiennej długości. W przeciwieństwie do niektórych innych typów sieci neuronowych, takich jak CNN, które wymagają danych wejściowych o stałym rozmiarze, ten model może przyjmować dane wejściowe o różnej długości. Architektura warstwy bi-kierunkowej LSTM przedstawiona jest na rysunku 2.



Rys. 1: Vanilla architektura LSTM

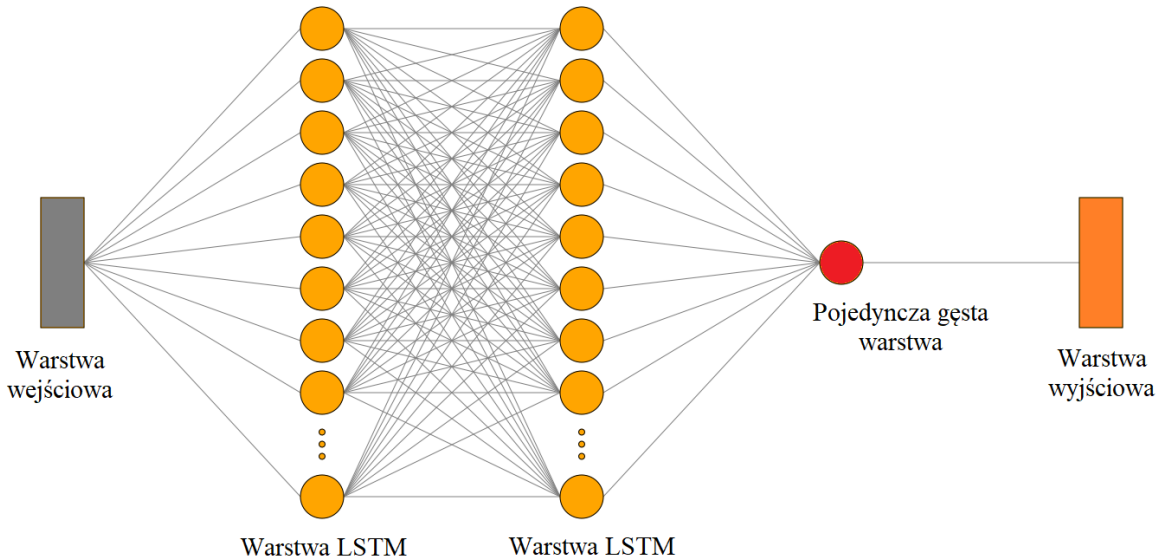
Architektura tego modelu jest podobna do modelu podstawowego w zakresie wejścia, wyjścia i pojedynczej warstwy gęstej. Jednak kluczowa różnica tkwi w warstwie dwukierunkowej LSTM, która analizuje dane pod kątem zależności czasowych w obu kierunkach, w przeciwieństwie do jednokierunkowej analizy warstwy podstawowej LSTM, jak wcześniej wspomniano. Model ten wykazuje lepszą zdolność do wykrywania i uwzględniania zależności czasowych w danych, co może przyczynić się do poprawy jakości prognoz.



Rys. 2: Model dwukierunkowej sieci LSTM

Model stosowanej sieci LSTM jest bardziej zaawansowaną wersją prostego modelu podstawowego i lepiej nadaje się do nauki skomplikowanych zależności czasowych. Na rysunku 3 przedstawiono architekturę stosowanej sieci LSTM, składającą się z dwóch warstw LSTM.

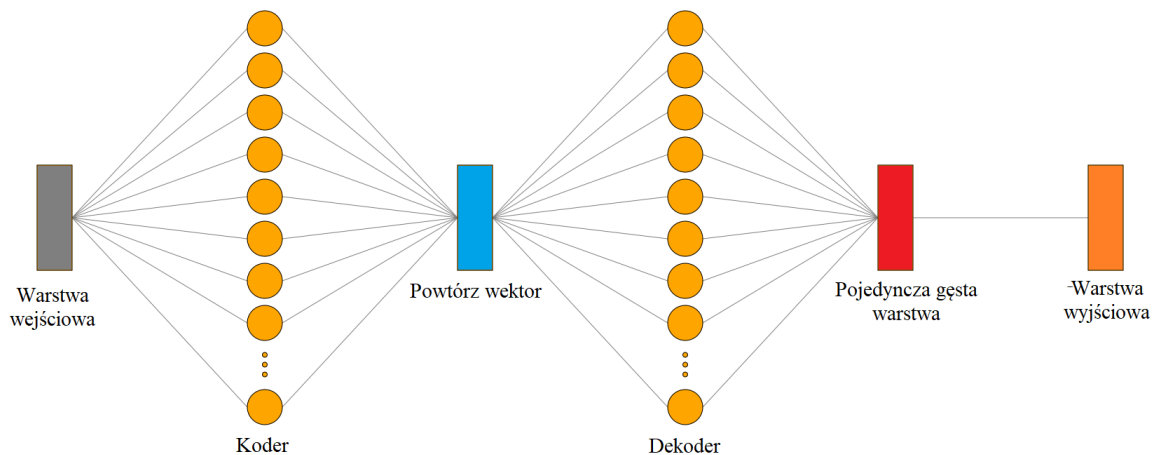
Charakterystyczną cechą tego modelu jest początkowa warstwa LSTM, która generuje nauczonych reprezentacji na podstawie danych z warstwy wejściowej. Następnie te reprezentacje są wykorzystywane przez kolejną warstwę LSTM do wydobycia bardziej złożonych zależności w danych. Ostatecznie pojedyncza warstwa gęsta i warstwa wyjściowa współpracują w celu dokonywania prognoz.



Rys. 3: Model stosowanej sieci LSTM

Jedną z wad stosowania modelu stosowanej sieci LSTM jest potencjalne występowanie nadmiernego dopasowania do danych treningowych. Z większą liczbą parametrów i większą zdolnością do nauki skomplikowanych wzorców, modele stosowanej sieci LSTM mogą być bardziej podatne na nadmierną naukę niż prostsze modele. Jest to ostrożnie kontrolowane poprzez zarządzanie epokami treningowymi i monitorowanie krzywych straty testowo-treningowej.

Rysunek 4 przedstawia model LSTM Autoencoder wykorzystany w tej studii, składający się z warstw kodera, dekodera i warstwy repeat vector. Warstwa kodera jest odpowiedzialna za generowanie nauczonych reprezentacji w postaci wektora, który ujmie złożoną dynamikę czasową danych wejściowych. Skompresowany wektor może być również wykorzystywany w połączeniu z innymi algorytmami uczenia maszynowego/głębokiego, ponieważ w tym etapie następuje redukcja wymiarów danych. Zakodowany wektor jest następnie przekazywany do warstwy dekodera za pomocą repeat vector, a ogólna wydajność modelu zależy od zdolności dekodera do dokładnego odtworzenia wektora wejściowego. W niniejszym badaniu zarówno warstwa kodera, jak i dekodera zawierają po trzy komórki, ale to może być zmieniane w zależności od złożoności danych wejściowych i pożądanego stopnia kompresji.

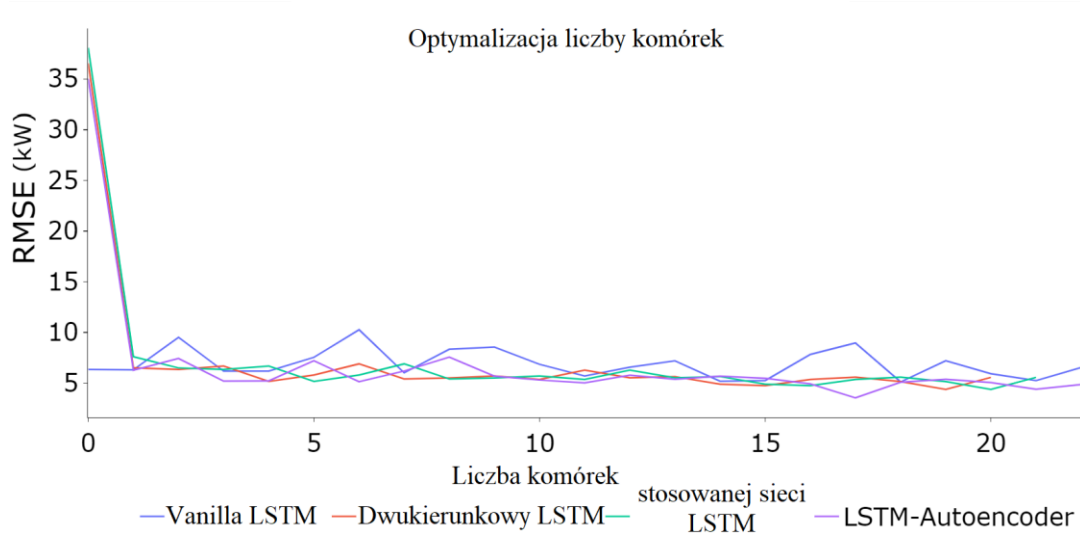


Rys. 4: Model LSTM Autoencoder

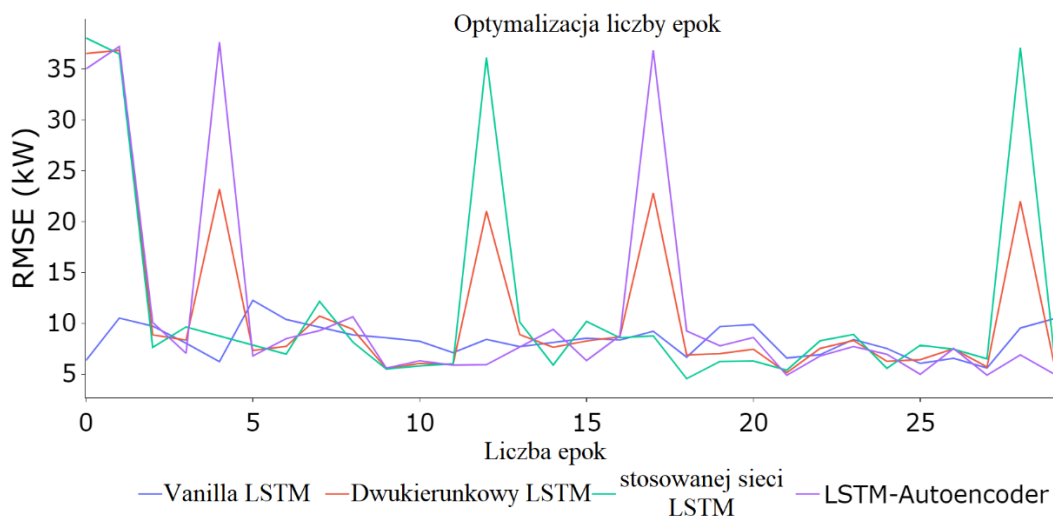
Wada stosowania modelu LSTM Autoencoder polega na określeniu odpowiedniego stopnia kompresji dla danych wejściowych. Zbyt mała kompresja może nie przynieść znaczącego zmniejszenia rozmiaru danych, podczas gdy zbyt duża kompresja może prowadzić do utraty istotnych informacji lub nadmiernego dopasowania do danych treningowych. Techniki regularyzacji, takie jak dropout lub wczesne zatrzymywanie, mogą być stosowane w celu rozwiązania tych problemów.

Jednym z kluczowych wkładów w budowanie solidnego narzędzia prognostycznego opartego na głębokim uczeniu się jest optymalizacja architektury wyżej wyjaśnionych modeli. Przeprowadzono to w następujący sposób.

Na Rysunku 5 przedstawiono wartość RMSE dla danych testowych dla różnych architektur modeli LSTM, w zależności od liczby komórek użytych w warstwach LSTM. Warto zauważyć, że dla architektur z jedną komórką RMSE utrzymuje się na wysokim poziomie. Jednak dla większej liczby komórek wartość RMSE jest niższa i stabilizuje się. Dla modelu Vanilla LSTM optymalna wydajność osiągnięta została przy użyciu 4 komórek. Model dwukierunkowy również korzysta z 4 komórek w warstwie LSTM. Natomiast model stosowany składa się z dwóch warstw z łącznie 5 komórkami, a model LSTM Autoencoder zawiera 3 komórki. Aby wybrać odpowiednie funkcje aktywacji, funkcje straty i optymalizator dla każdego z modeli, przetestowano łącznie 48 kombinacji. Najlepsze wyniki uzyskano przy użyciu funkcji aktywacji ReLu, funkcji straty MSE i optymalizatora Adam. Wszystkie modele zostały trenowane przy rozmiarze partii wynoszącym 24, uwzględniającym 24 godziny poprzedzające prognozę.



Rys. 5: Optymalizacja liczby komórek



Rys. 6: Optymalizacja liczby epok

Rysunek 6 przedstawia wartość RMSE w zależności od liczby epok dla wszystkich badanych modeli na zbiorze testowym. Można zauważyć, że dla większości modeli, poza modelem Vanilla, początkowe wartości RMSE są stosunkowo wysokie do 5 epok, a następnie sporadycznie występują skoki do wyższych wartości RMSE. Dla modeli dwukierunkowego, stosowanego i LSTM Autoencoder najniższe wartości RMSE zostały osiągnięte po 9 epokach, podczas gdy dla modelu Vanilla osiągnięto to już po 4 epokach. Dlatego do treningu modeli wykorzystano odpowiednio 9 epok dla modeli dwukierunkowego, stosowanego i LSTM Autoencoder, oraz 4 epoki dla modelu Vanilla.

TABELA 1
VANILLA LSTM METRYKI STATYSTYCZNE

Miar	Minimalny (kW)	Mean (kW)	Maksymalny (kW)	95% przedział ufności (kW)
RMSE	0.06	15.72	38.67	[14.01 – 17.43]
MAE	0.06	8.30	18.25	[7.41 – 9.13]

TABELA 2
STOSOWANEJ SIECI LSTM METRYKI STATYSTYCZNE

Miar	Minimalny (kW)	Mean (kW)	Maksymalny (kW)	95% przedział ufności (kW)
RMSE	0.06	14.39	30.11	[12.87 – 15.85]
MAE	0.06	7.79	15.72	[6.97 – 8.62]

TABELA 3
DWUKIERUNKOWY LSTM METRYKI STATYSTYCZNE

Miar	Minimalny (kW)	Mean (kW)	Maksymalny (kW)	95% przedział ufności (kW)
RMSE	0.06	12.87	30.30	[11.53 – 14.20]
MAE	0.06	6.91	16.16	[6.657 – 8.43]

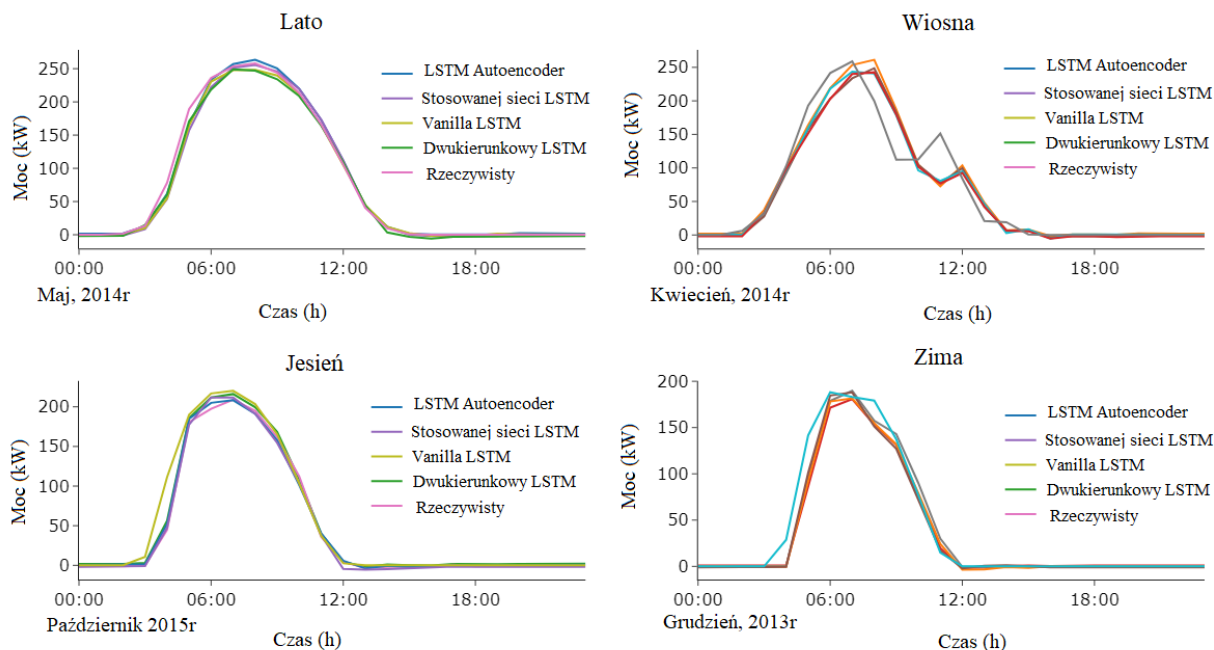
TABELA 4
LSTM-AUTOENCODER METRYKI STATYSTYCZNE

Miar	Minimalny (kW)	Mean (kW)	Maksymalny (kW)	95% przedział ufności (kW)
RMSE	0.31	15.59	39.94	[13.88 – 17.20]
MAE	0.31	8.36	22.25	[7.48 – 9.25]

Analizując przedstawione wyniki, można zauważyć pewne różnice pomiędzy modelami LSTM oraz ich metrykami statystycznymi. Patrząc na przedział ufności 95% dla błędów RMSE i MAE, można stwierdzić, że model dwukierunkowego LSTM (Tabela III) ma najwęższy przedział ufności w porównaniu z innymi modelami. Oznacza to, że wyniki predykcji tego modelu są bardziej skoncentrowane wokół średniej wartości, co sugeruje większą precyzję predykcji. Pod względem wartości minimalnej RMSE i MAE, modele Vanilla LSTM (Tabela I), z wartościami 0.06 kW, wydają się osiągać najlepsze wyniki. Są one minimalne, co sugeruje, że ten model może być bardziej odpowiedni, jeśli minimalizacja błędów jest kluczowym kryterium. Podsumowując, model dwukierunkowego LSTM może charakteryzować się węższym przedziałem ufności, co sugeruje większą precyzję predykcji. Jednak modele Vanilla LSTM osiągają minimalne wartości RMSE i MAE, co sugeruje, że mogą być bardziej odpowiednie, jeśli priorytetem jest minimalizacja błędów. W tym badaniu ostatecznie wybrano model autoenkodera LSTM, ponieważ reprezentuje on równowagę między krótkimi przedziałami ufności a dokładnością i nie opiera się tylko na jednej metryce, jak inne rozważane modele.

Rysunek 7 przedstawia wizualne porównanie modeli prognostycznych dla głównych pór roku obserwowanych w regionie. Te dni zostały losowo wybrane ze zbioru danych, który nie był pokazywany modelom podczas treningu. Widać, że dzień reprezentujący lato przypada na 9 maja. Wyraźnie widać, że panele fotowoltaiczne tego dnia pracują znacznie dłużej w porównaniu do dni zimowych i jesiennych, a moc szczytowa w ciągu dnia jest większa. Modele predycyjne sprawdzają się w tym przykładzie, ponieważ przewidywania modeli prawie pokrywają się z wartością prawdziwą. Vanilla LSTM, Stacked LSTM i dwukierunkowy LSTM są nieco niedoszacowane, podczas gdy LSTM-Autoencoder przewiduje zbyt wysokie. Drugi dzień, reprezentujący wiosnę, to 19 kwietnia, podczas którego moc utrzymuje się na stosunkowo wysokim poziomie, blisko szczytu 250 kW, a dzień jest długi w porównaniu z jesienią i zimą.

Prognoza punktu sezonowego



Rys. 7: Porównanie prognoz punktowych wszystkich badanych modeli dla losowych dni każdego sezonu


W tym przypadku widać, że modele prognostyczne nie odzwierciedlają rzeczywistej wartości tak dokładnie, jak latem. Może to wynikać z faktu, że w porównaniu z latem występują okresy wiosenne, kiedy światło słoneczne nie dociera do paneli fotowoltaicznych z powodu znacznego ruchu chmur. Powoduje to niewielkie szczyty i dołki w charakterystyce mocy wyjściowej, gdzie wysoka dokładność może być trudna do osiągnięcia. Trzeci dzień, odnoszący się do 28 października, reprezentuje sezon jesienny i widać, że moc szczytowa jest ograniczona do około 200 kW, czyli znacznie mniej niż zainstalowana moc szczytowa 317 kW. Na ten dzień prognozy bardzo dobrze odzwierciedlają rzeczywistą wartość. Dzieje się tak również dlatego, że w tym dniu nie ma dramatycznych zmian w charakterystyce, chociaż takie zmiany występują zarówno jesienią, jak i wiosną. Wszystkie testowane modele wydają się niedoszacowywać w tym przykładzie, a po bliższym przyjrzeniu się widać, że prognoza LSTM-Autoencoder jest najbliższa prawdziwej wartości. Czwarty dzień, reprezentujący zimę, przypada na 16 grudnia. Tego dnia można zauważyć, że moc szczytowa jest znacznie poniżej 200 kW. Przewidywania modelu odpowiadają rzeczywistym charakterystykom z dobrym stopniem dokładności, pomimo niewielkich nagłych zmian. Wszystkie testowane modele zaniżają większość dnia, a LSTM-Autoencoder wydaje się być dokładniejszy niż inne modele.

Podczas gdy wyżej wymienione modele zostały zbadane pod kątem prognozowania mocy fotowoltaicznej [1]. Nie jest to ograniczone dla tej aplikacji. Został również użyty w tych samych i zmodyfikowanych wersjach w [6],[7],[9].

W pracy [6] podjęto wyzwanie przewidywania dwukierunkowego przepływu mocy w sieci elektroenergetycznej, szczególnie w kontekście zwiększonej integracji odnawialnych źródeł energii i systemów magazynowania energii. Wahania zużycia energii wynikające z wytwarzania nadwyżek energii elektrycznej i dwukierunkowego przepływu energii stwarzają problemy z niezawodnością i bezpieczeństwem sieci. Dokładne przewidywanie przepływu mocy jest niezbędne do złagodzenia tych problemów. Jednak dynamiczny charakter charakterystyk przepływu mocy i wpływ pogody na wytwarzanie energii ze źródeł odnawialnych utrudniają osiągnięcie dokładności przewidywania. Zaproponowano dwa hybrydowe modele głębokiego uczenia (HDL): CNN-LSTM i LSTM-CNN. Modele te wykorzystują zalety konwolucyjnych sieci neuronowych (CNN) i sieci pamięci długoterminowej (LSTM). Modele są trenowane przy użyciu dwóch różnych zestawów danych, które różnią się rozmiarem i zawartymi parametrami. Celem jest ocena wpływu wielkości zbioru danych i uwzględnienia danych pogodowych na wydajność predykcyjną proponowanych modeli szacowania przepływu mocy.


Wyniki pokazują, że zarówno modele CNN-LSTM, jak i LSTM-CNN mogą uzyskać dokładne prognozy przepływu mocy w określonych warunkach. Warto zauważyć, że rozmiar i parametry zestawu danych wpływają zarówno na czas szkolenia, jak i dokładność modeli HDL. Badanie to przyczynia się do rozwoju solidnych modeli przewidywania przepływu mocy w badanym klastrze sieciowym, dostarczając cennych informacji w celu zwiększenia niezawodności i bezpieczeństwa sieci elektroenergetycznej.

Sieć CNN to odmiana modeli głębokiego uczenia się, znana z możliwości uczenia się abstrakcyjnych cech obiektów. Szczególnie nadaje się do wizualnej analizy i rozpoznawania obrazów. Ponadto model CNN może również obsługiwać dane sekwencyjne z wieloma zmiennymi, dzięki czemu nadaje się do zadań predykcyjnych. Typowy model CNN, jak pokazano na rysunku 8, składa się z kilku warstw: warstwy konwolucyjnej, warstwy łączącej, warstwy spłaszczającej i warstwy w pełni połączonej. Warstwa konwolucyjna przeprowadza ekstrakcję cech przy użyciu przesuwanego okna i podziału wagi. Warstwa puli zmniejsza rozmiar mapy obiektów i wyodrębnia cechy dominujące. Typowymi typami operacji łączenia w pulę są pulę maksymalne i średnie. Warstwa spłaszczająca przekształca dane w jednowymiarowy wektor, umożliwiając połączenie z w pełni połączoną warstwą zawierającą wagi, odchylenia i neurony. W pełni połączona warstwa jest często umieszczana przed warstwą wyjściową w sieci CNN.



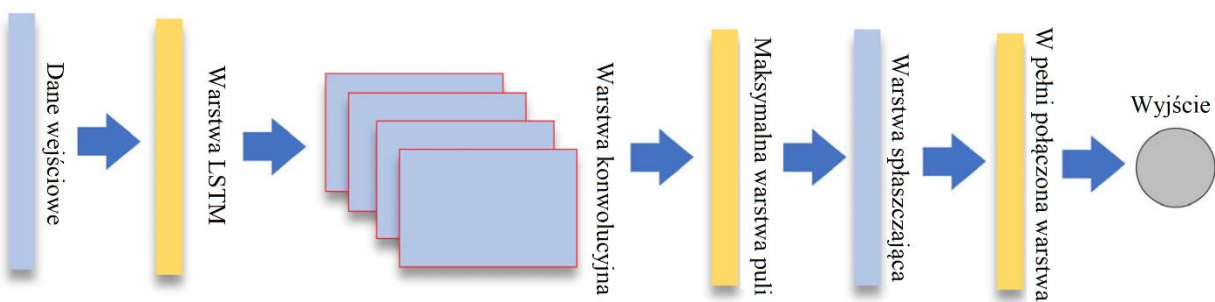
Rys. 8: Struktura sieci CNN

Architektura modelu CNN-LSTM pokazana na rysunku 9 została zaprojektowana z warstwami CNN na froncie w celu wyodrębnienia cech z wejściowego zestawu danych. Po tych warstwach CNN następowaly warstwy LSTM i gęsta warstwa na wyjściu, aby ułatwić przewidywanie sekwencji.



Rys. 9: Struktura modelu CNN-LSTM

W przeciwieństwie do tego model LSTM-CNN, jak pokazano na rycinie 10, ma inną strukturę sekwencyjną. W tym przypadku warstwy LSTM są wykorzystywane do uporządkowania wejściowych danych szeregów czasowych. Celem jest wykorzystanie warstw LSTM do przechwytywania i włączania nowych informacji do danych wyjściowych.

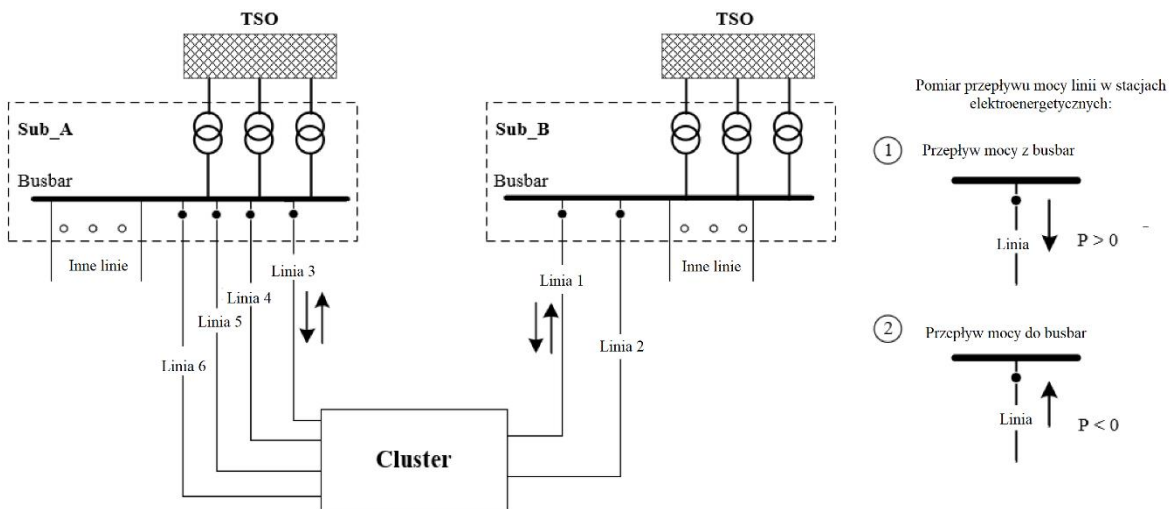


Rys. 10: Struktura modelu LSTM - CNN

Dane wyjściowe z warstw LSTM są następnie wprowadzane do warstw CNN w celu wyodrębnienia lokalnych cech. Następnie dane wyjściowe warstwy splotowej są łączone w celu zmniejszenia ich wymiarowości, zanim zostaną przekazane do warstwy gęstej w celu ostatecznej prognozy wyjściowej.

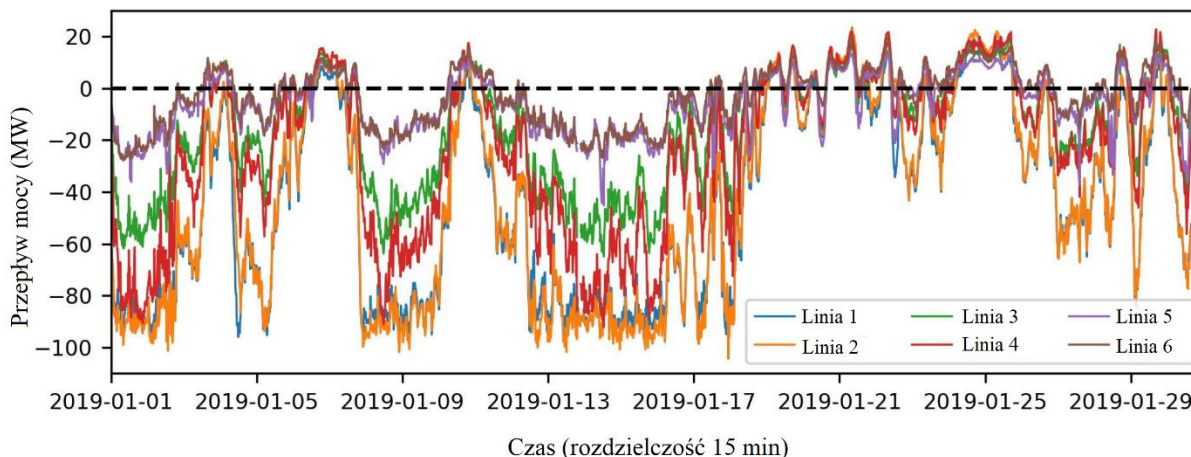
Integracja dużych elektrowni ze zdecentralizowanymi odnawialnymi źródłami energii (OZE) zwiększa złożoność systemu elektroenergetycznego. Zmienna generacja OZE i zmienne zachowania konsumentów wpływają na przepływ mocy w liniach. Aby uprościć system i przeanalizować efekty zdecentralizowanej generacji OZE, na styku operatorów systemów przesyłowych i dystrybucyjnych (OSP i OSD) tworzony jest regionalny klaster sieci elektroenergetycznej. Klaster tworzy się poprzez podział na strefy sieci elektroenergetycznej w oparciu o linie wysokiego napięcia i zaniedbanie połączeń wewnętrznych. Przykład takiego klastra sieciowego, zlokalizowanego w północno-wschodnich Niemczech, pokazano na rysunku 11.

Badany klaster sieciowy składa się z sześciu linii zasilających, z których cztery są podłączone do Podstacji A (Sub_A), a dwie do Podstacji B (Sub_B). Mierząc przepływ mocy w tych liniach zasilających, możemy zebrać istotne informacje na temat wytwarzania, obciążenia, importu i eksportu w ramach klastra sieci. Kierunek przepływu mocy jest wskazywany przez znak mierzonej mocy, jak pokazano na rysunku 11. W tym badaniu wykorzystaliśmy dwa modele HDL do przewidywania kierunku przepływu mocy na pojedynczej linii w oparciu o odniesienia wejściowe z innych istniejących linii. Badany klaster sieciowy posiada znaczącą instalację systemów OZE, w tym 365 MW systemów fotowoltaicznych i 630 MW turbin wiatrowych podłączonych do lokalnych sieci OSD. Uwzględniono również dane pogodowe, ponieważ odgrywają one kluczową rolę w regionalnym wytwarzaniu energii elektrycznej ze źródeł odnawialnych. Uwzględniając dodatkowe parametry warunków pogodowych wraz z wartościami przepływu mocy z innych linii zasilających, chcieliśmy zbadać potencjalny wpływ danych pogodowych na wyniki prognoz przepływu mocy.




Rys. 11: Zbadany klaster sieciowy

Aby przewidzieć kierunek przepływu mocy na poszczególnych liniach zasilających w badanym klastrze sieci, wykorzystano surowe dane kierunkowe pomiaru mocy dostarczone przez lokalnego operatora systemu dystrybucyjnego (OSD). Ten zestaw danych obejmuje zakres czasowy od 1 stycznia 2019 r. do 31 grudnia 2019 r. z rozdzielczością 15 minut. Kierunek przepływu mocy przedstawiono na rysunku 12, gdzie wartości dodatnie wskazują moc odpływającą z szyny do klastra, natomiast wartości ujemne wskazują moc płynącą w kierunku szyny z klastra sieci. Ten przykład pokazuje dynamikę przepływu mocy w klastrze sieciowym w szczególności w styczniu 2019 r.



Rys. 12: Rozpływ mocy we wszystkich liniach klastra sieciowego

Kierunek przepływu mocy w symulacji predykcyjnej wyznacza sama wartość przepływu mocy. Wartość mocy poniżej zera oznacza moc płynącą z klastra sieciowego do szyny zbiorczej, natomiast wartość powyżej zera wskazuje moc płynącą z szyny zbiorczej do klastra sieciowego. Wyniki przewidywania przepływu mocy dla wszystkich modeli głębokiego uczenia przedstawiono na rysunku 13. Rysunek ten ilustruje wyniki przewidywania dla testowego zestawu danych, obejmującego okres od 7 listopada 2019 r., 09:00 do 7 listopada 2019 r., 20:45. Modele głębokiego uczenia wykazują porównywalną wydajność w dokładnym śledzeniu oryginalnych pomiarów przepływu mocy (przedstawionych fioletową linią). Warto zauważyć, że wartości przepływu mocy na liniach zasilających 3 i 4 stale pozostają powyżej zera w tym okresie, co wskazuje na dominujący przepływ w kierunku klastra sieci. I odwrotnie, linie zasilające 1 i 2 konsekwentnie wykazują wartości przepływu mocy poniżej zera, co sugeruje nadwyżkę mocy z klastra sieci płynącej bezpośrednio do szyn zbiorczych. Warto zauważyć, że oryginalne wzorce przepływu mocy na liniach 1 i 2 wyglądają podobnie, ponieważ linie te są połączone równolegle. Podobnie linia 3 jest połączona równolegle z linią 4, a linia 5 jest równoległa do linii 6



Rys. 13: Wyniki predykcji kierunku przepływu mocy oparte wyłącznie na danych pomiarowych mocy rzeczywistej.

W [7] cel był podobny do [6], ale podejście i zastosowany model były inne, gdzie chodziło o wdrożenie wieloetapowego dwukierunkowego prognozowania przepływu mocy poprzez wprowadzenie modelu autoenkodera LSTM. Aby zoptymalizować wydajność modeli, podczas fazy uczenia zastosowano hiperparametry automatycznego dostrajania. Zaproponowany model wraz z modelami bazowymi został opracowany i dopracowany przy użyciu tych technik. Model LSTM Autoencoder wykorzystał informacje z poprzednich 6 godzin (co odpowiada 24 krokom 15-minutowych interwałów) do przewidywania przepływu mocy na następną godzinę (4 kroki 15-minutowych interwałów) na podstawie aktualnego czasu. Model LSTM Autoencoder został już opisany na rysunku 4 w celu jego wykorzystania w prognozowaniu energii fotowoltaicznej

Kluczowym wkładem tego artykułu jest wykorzystanie techniki hiperparametrów automatycznego dostrajania przy użyciu algorytmu hiperpasmowego z tunera Keras w celu optymalizacji modeli głębokiego uczenia. Zarówno modele bazowe, jak i proponowany autoenkoder LSTM zostały poddane tej technice na etapie szkolenia modelu. Technika hiperparametrów automatycznego dostrajania ułatwiła poszukiwanie optymalnych wartości kluczowych hiperparametrów, w tym liczby neuronów w warstwach ukrytych, funkcji aktywacji i wartości współczynnika uczenia do optymalizacji. Technika automatycznego dostrajania hiperparametrów oferowała kilka korzyści, takich jak zwiększona efektywność treningu i lepsza jakość modelu. Wyeliminowało to potrzebę ręcznej eksploracji wielu kombinacji hiperparametrów, co może być czasochłonne i trudne w przypadku modeli głębokiego uczenia. Algorytm hiperpasmowy, zastosowany jako tuner w tym badaniu, wykorzystywał metodę sukcesywnego zmniejszania o połowę, aby iteracyjnie


eliminować słabo działające konfiguracje. Wykorzystując algorytm hiperpasmowy z odpowiednimi ustawieniami, skutecznie zbadano przestrzeń hiperparametryczną, co doprowadziło do identyfikacji optymalnych konfiguracji dla modeli głębokiego uczenia. W tym badaniu tuner hiperpasmowy został skonfigurowany tak, aby zminimalizować utratę walidacji. Maksymalną liczbę epok do uczenia każdej konfiguracji modelu ustalono na dziesięć, a algorytm wykorzystał współczynnik trzy do określenia liczby konfiguracji w każdym nawiasie.

W tym badaniu oceniono następujące modele: Simple RNN, LSTM, GRU, Dwukierunkowy LSTM i LSTM Autoencoder. Tabela 5 podsumowuje wyniki oceny każdego wytrenowanego modelu głębokiego uczenia przy użyciu zestawu danych testowych.

TABELA 5. OCENA WYDAJNOŚCI MODELU PROGNOSTYCZNEGO

Nazwa modelu	RMSE	MAE	R ²
Proste RNN	36.238	28.127	0.912
LSTM	38.646	29.398	0.9
GRU	32.377	24.352	0.93
Dwukierunkowy LSTM	32.486	24.552	0.929
LSTM Autoencoder	32.243	24.154	0.93


Wyniki oceny pokazują, że model LSTM Autoencoder osiąga najniższe wyniki RMSE i MAE odpowiednio 32,243 i 24,154, co wskazuje na jego doskonałą wydajność w przewidywaniu przepływu mocy. Model GRU również wykazuje dobre wyniki, z drugimi najniższymi wynikami RMSE i MAE wynoszącymi odpowiednio 32,377 i 24,352. Ponadto zarówno model LSTM Autoencoder, jak i dwukierunkowy LSTM wykazują wysokie wyniki R2 wynoszące 0,930, co dodatkowo potwierdza ich dokładność i skuteczność w przewidywaniu przepływu mocy.




Rys. 14: Wieloetapowa prognoza przepływu mocy dla wszystkich wytrenowanych modeli

Rysunek 14 ilustruje wyniki prognozowania wieloetapowego przepływu mocy dla dwukierunkowego przepływu mocy ze wszystkich wyuczonych modeli, w tym proponowanego modelu autoenkodera LSTM i modeli bazowych. Testowy zestaw danych wejściowych w tej analizie obejmuje ostatnie 6 godzin i obejmuje 24 kroki z 15-minutową przerwą, począwszy od bieżącego czasu. W szczególności dane wejściowe obejmują zakres czasu od „2019-11-29T10:45:00” do „2019-11-29T16:30:00”. Dane wejściowe są wprowadzane do wyszkolonych modeli w celu przewidywania dwukierunkowego przepływu mocy o 1 godzinę do przodu (cztery kroki po 15 minut) po bieżącym czasie w badanym klastrze sieciowym. Oczekiwane dane


wyjściowe obejmują zakres czasowy od '2019-11-29T16:45:00' do '2019-11-29T17:30:00'. Biorąc pod uwagę lepszą wydajność naszego proponowanego modelu autoenkodera LSTM w porównaniu z modelami bazowymi, o czym świadczą wyniki oceny modelu, rozszerzamy prognozę za pomocą naszego autoenkodera LSTM. To rozszerzenie obejmuje rozszerzenie zestawu danych testowych o dodatkowe cztery kroki 15-minutowych wyników prognozy interwałowej z ruchomego okna wejściowego zestawu danych. Celem tego rozszerzenia jest dostarczenie bardziej kompleksowych informacji i zwiększenie wiarygodności prognozowanych wyników.



(a)



(b)



(c)

Rys. 15: Wielostopniowe prognozy rozplywu mocy wygenerowane przez autoenkoder LSTM w dniu 29 listopada 2019 r. dla określonych przedziałów czasowych: (a) 17:45:00–18:30:00, (b) 18:45:00–19:30:00 oraz c) 19:45:00–20:30:00.

Na rysunku 15 przedstawiono kontynuację wyników prognozy mocy dla rozplywów mocy w klastrze sieciowym. W szczególności badamy scenariusz, w którym wartości wejściowe zmieniają

się co godzinę, składający się z czterech kroków 15-minutowych interwałów, po godzinie rozpoczęcia „2019-11-29T10:45:00”, jak pokazano na rysunku 14. Rysunek 15a przedstawia wykorzystanie proponowanego modelu, przy użyciu danych wejściowych w zakresie od „2019-11-29T11:45:00” do „2019-11-29T17:30:00”, do przewidywania czterech wartości obejmujących okres od „2019-11-29T17:45:00” do „2019-11-29T18:30:00”. Na rysunku 15b autoenkoder LSTM generuje prognozy przepływu mocy z 1-godzinnym wyprzedzeniem, obejmujące zakres czasu od „2019-11-29T18:45:00” do „2019-11-29T19:30:00”. Dane wejściowe użyte do tej prognozy odpowiadają przedziałowi od „2019-11-29T12:45:00” do „2019-11-29T18:30:00”. Ponadto rysunek 15c przedstawia prognozowane wyniki autoenkodera LSTM do przewidywania przepływu mocy z 1-godzinnym wyprzedzeniem, obejmujące zakres czasu „2019-11-29T19:45:00” do „2019-11-29T20:30:00”. Aby osiągnąć tę prognozę, wykorzystane dane wejściowe obejmują przedział od „2019-11-29T13:45:00” do „2019-11-29T19:30:00”.

W pracy [9] rozważano czynnik czasu jednowymiarowych danych szeregów czasowych w celu wdrożenia różnych modeli głębokiego uczenia się do przewidywania obciążenia na godzinę do przodu. Celem było zidentyfikowanie najbardziej odpowiedniego modelu dla różnych warunków, w tym wahań sezonowych i dziennych. Zaproponowano dwa hybrydowe modele głębokiego uczenia się, łączące dekompozycję trybu wariacyjnego (VMD) z konwolucyjnymi sieciami neuronowymi (CNN) i bramkowanymi jednostkami rekurencyjnymi (GRU) w jednym modelu oraz z CNN i pamięcią długoterminową (LSTM) w innym modelu. Zaproponowane modele wykazały lepszą wydajność w porównaniu z modelami podstawowymi. Model VMD-CNN-LSTM wykazał się doskonałą wydajnością w warunkach sezonowych, osiągając średni błąd średniokwadratowy (RMSE) na poziomie 12,215 kW, średni błąd bezwzględny (MAE) na poziomie 9,543 kW i średni bezwzględny błąd procentowy (MAPE) na poziomie 0,095%. Z drugiej strony model VMD-CNN-GRU działał dobrze dla wahań dobowych, ze średnią wartością RMSE 11,595 kW, MAE 9,092 kW i MAPE 0,079%.

Chociaż poszczególne modele zostały wyjaśnione wcześniej, w tym artykule rozważono ich nowe kombinacje. Jednym z kluczowych wkładów artykułu jest wykorzystanie VMD w przetwarzaniu danych w połączeniu z badanymi modelami głębokiego uczenia się. Algorytm VMD jest wykorzystywany do dekompozycji oryginalnego sygnału na zbiór funkcji trybu reprezentujących różne składowe oscylacje przy różnych częstotliwościach i skalach. Poprzez iteracyjny proces optymalizacji tryby te są generowane przez minimalizację funkcji kosztu w celu skutecznego wyodrębnienia trybów. W kontekście empirycznej dekompozycji modów, te mody są określane jako sygnały, które wykazują różnicę co najwyżej jednego między liczbą lokalnych ekstremów i przejść przez zero. W kolejnych badaniach definicja ta została nieco zmodyfikowana i nazwana funkcjami trybu wewnętrznego (IMF). Głównym celem algorytmu VMD jest rozwiązanie problemu wariacyjnego. Osiąga to poprzez dekompozycję sygnału wejściowego o wartościach rzeczywistych na zestaw podsygnałów lub trybów, oznaczonych jako u_k , które posiadają określone właściwości rzadkości, a jednocześnie dokładnie reprezentują oryginalny sygnał. Metoda ma na celu zminimalizowanie całkowitej szerokości pasma częstotliwości przy jednoczesnym zapewnieniu, że suma rozłożonych modów odpowiada oryginalnemu sygnałowi wejściowemu. Ten cel i ograniczenie można przedstawić za pomocą równania 1.

$$\min_{\{u_k\} \quad \{\omega_k\}} \left\{ \sum_{k=1}^N \left\| \vartheta(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$s. t. \sum_{k=1}^N u_k(t) = f(t)$$

W podanym kontekście K oznacza pożądaną liczbę modów do rozłożenia, która jest dodatnią liczbą całkowitą. $\{u_k\}$ i $\{\omega_k\}$ reprezentują odpowiednio k -tą składową modalną i częstotliwość środkową. Funkcja δ_t reprezentuje funkcję Diraca, a $(*)$ wskazuje operator splotu. Aby poradzić sobie z ograniczeniem rekonstrukcji przedstawionym w równaniu 1, sformułowano nieograniczony problem, wprowadzając kombinację kwadratowego składnika karnego i mnożników Lagrange'a. To rozszerzone wyrażenie Lagrange'a jest przedstawione jako Równanie 2.

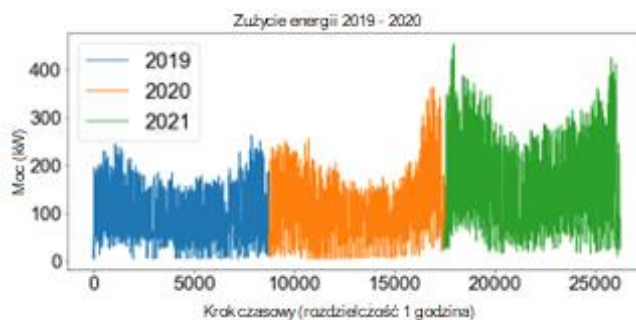
$$L(\{u_k\}, \{\omega_k\}, \lambda) := \alpha \sum_k \left\| \vartheta(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (2)$$

Dane dotyczące obciążenia energią elektryczną wykorzystane w tym badaniu uzyskano z zakładu metalurgicznego zlokalizowanego w Polsce. Zbiór danych zawiera jednowymiarowe dane szeregów czasowych reprezentujące zużycie energii elektrycznej mierzone w kilowatach (kW). Dane obejmowały okres od 1 stycznia 2019 r. do 31 grudnia 2021 r. i zostały zebrane za pomocą pomiarów jakości energii lub inteligentnych liczników dostarczonych przez przedsiębiorstwo użyteczności publicznej. Początkowo dane rejestrowano w odstępach 15-minutowych, co skutkowało częstotliwością próbkowania wynoszącą 4 próbki na godzinę, obliczoną jako odwrotność przedziału czasu (1/0,25). Jednak ze względu na cel badania, jakim było przewidywanie zużycia energii na godzinę do przodu w różnych okolicznościach, oryginalny zestaw danych szeregów czasowych został sztucznie ponownie próbkowany do 1-godzinnej szczegółowości. Ten proces ponownego próbkowania obejmuje różne metody, takie jak agregacja danych, w celu przekształcenia danych z interwału 15-minutowego na interwał 1-godzinny. Zgodnie z proponowaną metodologią zestaw danych został poddany technikom wstępnego przetwarzania, w tym normalizacji danych, restrukturyzacji danych przy użyciu metody przesuwanego okna i podziału zbioru danych. Te kroki mają na celu przygotowanie odpowiedniego zestawu danych dla modelu głębokiego uczenia się.

TABELA 6. OPIS STATYSTYCZNY ZBIORU DANYCH OBCIĄŻENIA ELEKTRYCZNEGO


Rok	Pora roku	numer punktu danych	Minimalny [kW]	Średnia wartość [kW]	Maksymalny [kW]
2019	Zima	2136	4.86	89.6	251.34
	Wiosna	2207	4.71	73.29	226.77
	Lato	2208	4.5	67.06	184.62
	Jesień	2185	4.32	82.77	262.41
	Dzień roboczy	6240	4.86	90.70	262.41
	Weekend	2496	4.32	46.53	170.31
2020	Zima	2160	8.07	113.61	364.89
	Wiosna	2207	4.32	79.16	255.39
	Lato	2208	4.53	77.26	176.34
	Jesień	2185	6.57	101.07	339.24
	Dzień roboczy	6264	5.16	112.46	364.89
	Weekend	2496	4.32	42.91	273.15
2021	Zima	2160	10.38	157.35	453.9
	Wiosna	2207	16.32	129.7	370.92
	Lato	2208	19.08	116.31	285.69
	Jesień	2184	15.36	141.01	361.95
	Dzień roboczy	6264	17.22	159.92	453.9
	Weekend	2495	10.38	75.83	265.02

Rysunek 16 ilustruje pierwotny schemat zużycia energii w zbiorze danych, ujawniając stały wzrost zużycia energii elektrycznej rok po roku. Analiza zbioru danych w ujęciu rocznym (jak pokazano w tabeli 6) pokazuje, że roczne zużycie energii wzrosło z 682 MWh w 2019 r. do 811,5 MWh w 2020 r., a następnie wzrosło do 1190,9 MWh do końca 2021 r. (jak pokazano na rysunku 17). Ponadto, biorąc pod uwagę określone okoliczności, takie jak kategorie dni i kategorie pór roku, pojawiają się wyraźne wzorce (również pokazane na rysunku 17). Największy udział w rocznym zużyciu energii elektrycznej ma zima, przekraczająca 27%, a następnie jesień, wiosna i lato. W dni powszednie zużycie energii elektrycznej jest wyższe niż w weekendy, przy czym ponad 80% zużycia energii przypada na dni powszednie.



Rys. 16: Zużycie energii elektrycznej

Tendencje te wskazują na sezonowe i dni powszednie/weekendowe wahania zapotrzebowania na obciążenie. W związku z tym niniejsze badanie koncentruje się na zbadaniu hipotezy, że wydajność modeli głębokiego uczenia się do prognozowania obciążenia elektrycznego z godzinnym wyprzedzeniem znacznie różni się w różnych warunkach w przemyśle metalurgicznym. W związku z tym wymagane są oddzielne modele prognostyczne dla każdego warunku, aby dokładnie przewidzieć zapotrzebowanie na obciążenie.



Rys. 17: Roczne zużycie energii

Tabela 3 przedstawia kompleksowe porównanie czasów obliczeń dla modeli predykcyjnych DL podczas fazy uczenia przy użyciu różnych zestawów danych. Wyniki w Tabeli 3 wskazują, że model GRU wymaga najdłuższego czasu uczenia, nie tylko dla prognoz sezonowych, ale także dla dni roboczych i zbiorów danych weekendowych. Model LSTM ma również stosunkowo dłuższe czasy szkolenia. Można to przypisać sekwencyjnemu charakterowi przetwarzania zarówno modeli GRU, jak i LSTM, gdzie każdy kolejny krok zależy od danych wyjściowych poprzedniego kroku

TABELA 7. COMPUTATIONAL TIME OF DL DURING TRAINING STAGE.


DL models	Training time [sekundy]					
	Winter	Spring	Summer	Autumn	Working day	Weekend
MLP	29.143	28.093	25.169	25.983	78.615	36.82
LSTM	92.823	85.917	85.456	87.381	254.36	107.855
GRU	108.459	99.565	98.665	102.724	319.193	135.598
CNN	31.152	28.723	27.927	29.089	93.256	44.678
CNN-LSTM	43.686	40.219	40.292	41.237	137.742	65.437
CNN- GRU	38.539	41.394	40.32	42.14	203.916	83.274
VMD-CNN-LSTM	77.465	84.121	84.269	84.12	204.108	68.36
VMD-CNN-GRU	84.472	84.259	60.182	59.409	178.587	84.396

Natomiast model wielowarstwowego perceptronu (MLP) jest najszybszym modelem prognozowania DL podczas treningu. Proponowane modele, VMD-CNN-LSTM i VMD-CNN-GRU, wykazują czasy szkolenia mieszczące się w umiarkowanym zakresie. Zajmują pozycję

między dłuższymi czasami trwania obserwowanymi w niektórych modelach a szybkością MLP. Po dokładnym zbadaniu modele te wykazują zadowalającą przydatność do opracowywania prognoz obciążenia w różnych warunkach.




Rys. 18 (a): Jednodniowa prognoza obciążenia - sezon zimowy



Rys. 18 (b): Jednodniowa prognoza obciążenia - sezon wiosenny



Rys. 18 (c): Jednodniowa prognoza obciążenia - sezon letni



Rys. 18 (c): Jednodniowa prognoza obciążenia - sezon jesienny

Rysunek 11 przedstawia wyniki prognoz proponowanych modeli, VMD-CNN-LSTM i VMD-CNN-GRU, do przewidywania obciążenia elektrycznego zakładu metalurgicznego o godzinę do przodu w różnych warunkach sezonowych. Na rysunku 11(a) obserwujemy jednodniową prognozę obciążenia w sezonie zimowym, obejmującą okres od „2021-12-05T08:00:00” do „2021-12-06T07:00:00”. Podobnie, rysunek 11(b) przedstawia wynik przewidywania jednodniowej prognozy obciążenia elektrycznego w sektorze metalurgicznym w okresie wiosennym, obejmującego zakres czasowy od „2021-05-04T15:00:00” do „2021-05-05T14:00:00”. Ponadto na rysunku 11(c) przedstawiono jednodniową prognozę obciążenia elektrycznego w sezonie letnim, obejmującą okres od „2021-08-04T15:00:00” do „2021-08-05T14:00:00”. Wreszcie, rysunek 11(d) przedstawia wyniki przewidywania obciążenia elektrycznego w sezonie jesiennym, w szczególności od „2021-11-03T22:00:00” do „2021-11-04T21:00:00”.

II. Inteligentne zarządzanie rozproszonymi zasobami energii.

W tej części znajdują się głównie prace związane z zarządzaniem rozproszonymi źródłami energii, w tym zarządzanie systemami akumulatorów, układ magazynowania wodoru i generatorami energii odnawialnej. We wszystkich opisanych pracach funkcją celu dotyczy minimalizacji kosztów operacyjnych.

Artykuł [2] koncentruje się na rozwiązaniu problemu ekonomicznej wysyłki w mikrosieciach. Początkowo do rozwiązania problemu optymalnego przepływu mocy dla systemu magistrali IEEE 30 stosowane są tradycyjne i nowo wprowadzone algorytmy optymalizacji metaheurystycznej. W drodze porównania wybierany jest najlepiej działający algorytm w celu uzyskania ekonomicznej wysyłki w mikrosieci opartej na obiekcie mikrosieci na Politechnice Wrocławskiej. Wszystkie algorytmy są zintegrowane z akademickim narzędziem do analizy mocy MATPOWER, którego celem jest znalezienie równowagi między możliwościami metaheurystyki w zakresie wyszukiwania rozwiązań a zoptymalizowaną wydajnością MATPOWER. Badane algorytmy obejmują trzy tradycyjne algorytmy: Genetic Algorithm, Particle Swarm Optimization and Mixed Integer Distributed Ant Colony Optimization. Dodatkowo zbadano dwa niedawno opracowane algorytmy, a mianowicie Political Optimizer i Lichtenberg Algorithm. Dostrajanie hiperparametrów jest przeprowadzane dla wszystkich badanych algorytmów. Wyniki pokazują, że

algorytm oparty na koloniach mrówek okazuje się najbardziej odpowiedni spośród dostępnych opcji. Wykazuje najlepszy czas zbieżności 19,17 s, osiąga końcową wartość rozwiązania 801,57 (\$/h) i wykazuje niezawodność w odtwarzaniu najlepszego rozwiązania dla systemu testowego. W konsekwencji algorytm ten wykorzystywany jest do ekonomicznej dyspozycji, kierującej się funkcją celu mającą na celu minimalizację uśrednionego kosztu energii w mikrosieci.

Najbardziej godnym uwagi wkładem tego artykułu jest optymalizacja hiperparametrów algorytmów optymalizacyjnych, które zostały zbadane.


W tym badaniu przeprowadzono obszerną eksplorację hiperparametrów dla każdego algorytmu optymalizacji, aby zidentyfikować najlepsze kombinacje, które zapewniają minimalny koszt operacyjny dla systemu magistrali IEEE-30. W przypadku Genetic Algorithm (GA) zoptymalizowano różne hiperparametry, w tym funkcję krzyżowania, wielkość populacji, frakcję krzyżowania, metodę skalowania sprawności, operatora mutacji i procedurę selekcji. Dało to w sumie 4800 kombinacji, a najlepszą kombinację przedstawiono w tabeli 8, osiągając minimalizację kosztów na poziomie 801,57 (\$/h). W celu Particle Swarm Optimization (PSO) zoptymalizowano hiperparametry, takie jak rozmiar roju, minimalny adaptacyjny rozmiar sąsiedztwa, waga samoregulacji i waga dostosowania społecznego. Oceniono łącznie 540 kombinacji, a najlepszą kombinację podsumowano w tabeli 8, co skutkowało minimalizacją kosztów na poziomie 801,64 (\$/godz.).

TABELA 8: USTAWIENIA HIPERPARAMETRÓW DLA EKSPLOWANYCH ALGORYTTMÓW

GA	PSO	MIDACO	PO	LA
Crossover function: Crossover laplace	Creation function: równomierny rozkład cząstek	Focus: '0', Parametr wymuszający poszukiwanie przez algorytm minimum globalnego.	Number of parties: 30	Refinement: 0.5
Crossover Fraction: 1	Adaptive inertia range: [0.1, 1.1]	Kernel Size: 50	Lambda: 0.8	No. of particles: 20
Wielkość populacji: 250	Rozmiar roju: 200	Liczba mrówek: 200	Wielkość populacji: 900 (parties*parties) zalecane przez dewelopera	Wielkość populacji: 24*10 (zalecane przez dewelopera)
Fitness Scaling: Based on top individuals	Minimum adaptive neighbourhood size: 0.5	-	Dimension: 24	Stick probability: 0.4
Mutation operator: Liczba losowa wzięta z rozkładu gaussowskiego	Self-adjustment weight = 1.25	-	-	Creation radius: 75
Selection procedure: Selection stochastic uniform	Social adjustment weight = 1.25	-	-	M value = 0
kryteria zatrzymania: tolerancja funkcji: 0.01	kryteria zatrzymania: tolerancja funkcji: 0.01	kryteria zatrzymania: tolerancja funkcji: 0.01	kryteria zatrzymania: tolerancja funkcji: 0.01	kryteria zatrzymania: tolerancja funkcji: 0.01

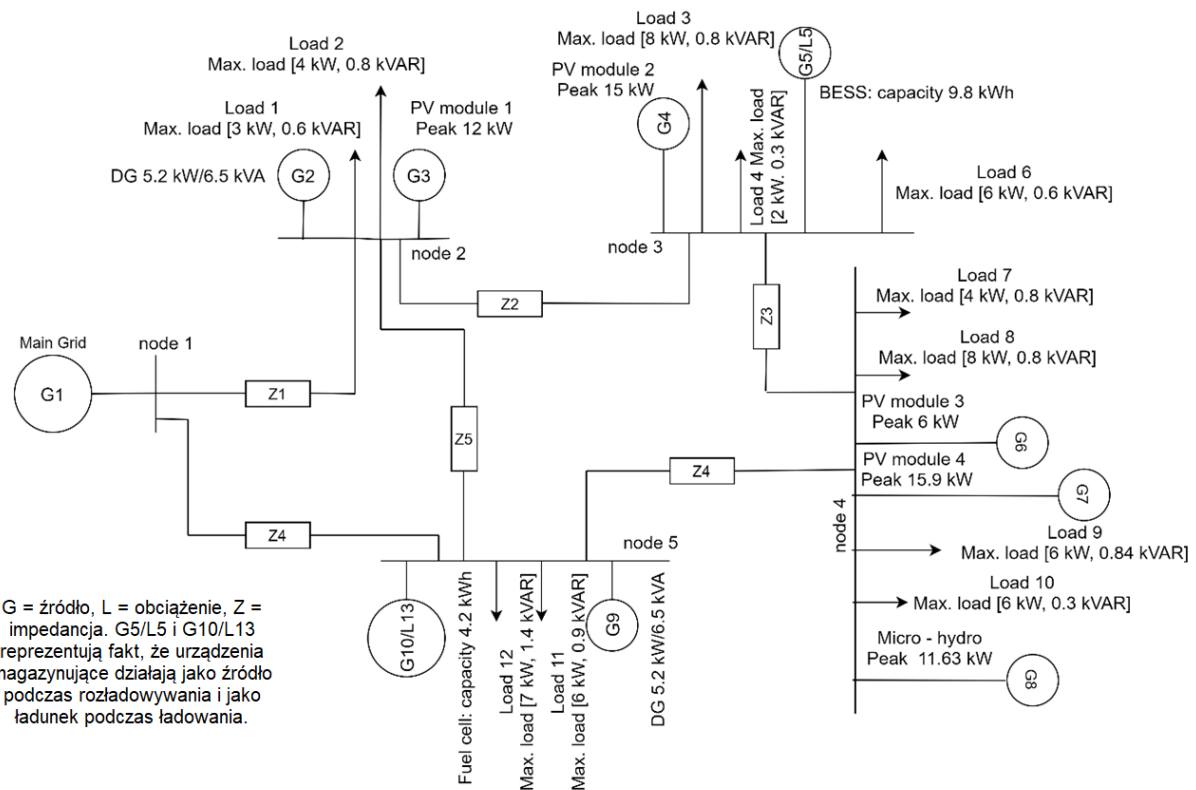
Mixed Integer Distributed Ant Colony Optimization (MIDACO) uwzględniał optymalizację hiperparametrów, w tym rozmiaru jądra i liczby mrówek. W sumie zbadano 16 kombinacji, a najlepszą kombinację przedstawiono w tabeli 8, osiągając minimalizację kosztów na poziomie 801,57 (\$/h). Algorytm Political Optimizer (PO) obejmował optymalizację hiperparametrów, takich jak liczba partii i lambda. Wymiar problemu ustalono na 24, a wielkość populacji na dwukrotność liczby partii. W sumie przeanalizowano 20 kombinacji, a najlepszą kombinację podsumowano w tabeli 8, co skutkowało minimalizacją kosztów na poziomie 801,57 (\$/godz.). W przypadku Lichtenberg Algorithm (LA) zoptymalizowano hiperparametry, w tym parametr udoskonalania, liczbę cząstek, prawdopodobieństwo przywierania i promień tworzenia. Wielkość populacji była zależna od liczby cząstek. W sumie zbadano 240 kombinacji, a najlepszą kombinację przedstawiono w tabeli 8, osiągając minimalizację kosztów na poziomie 801,60 (\$/h). Ogólnie rzecz biorąc, badanie obejmowało kompleksową analizę hiperparametrów dla każdego algorytmu optymalizacyjnego, w wyniku czego zidentyfikowano najlepsze kombinacje, które zapewniają najniższe koszty operacyjne rozważanego systemu.

Charakterystyki zbieżności badanych algorytmów przedstawiono na poniższym rysunku. Pierwsza iteracja dla algorytmu MIDACO nie została pokazana na rysunku ze względu na jej początkową wartość 833 \$/h, co utrudniałoby analizę. Z rysunku widać wyraźnie, że algorytm genetyczny (GA) wymaga największej liczby ocen funkcji, zanim zostanie spełniona tolerancja funkcji 0,01. Algorytm optymalizacji roju cząstek (PSO) ma drugą co do wielkości liczbę ocen funkcji. Z drugiej strony algorytm MIDACO, algorytm Lichtenberga (LA) i optymalizator polityczny (PO) wykazują podobne zachowanie zbieżności, z porównywalną liczbą ocen funkcji w zakresie od 2500 do 3500.



Rys. 19: Charakterystyka konwergencji

Zastosowany w pracy model mikrosieci jest rozszerzoną i zmodyfikowaną wersją instalacji mikrosieci na Politechnice Wrocławskiej. Model obejmuje łącznie 10 generatorów i 13 obciążeń, co stanowi system integrujący zarówno nieodnawialne, jak i odnawialne źródła energii. Generatory odnawialne obejmują panele słoneczne, mikro elektrownie wodne, generatory diesla (DG), system magazynowania energii litowo-jonowej (LESS) oraz ogniwo paliwowe połączone ze zbiornikiem do przechowywania wodoru (FC+HST). Dane dla paneli słonecznych są pozyskiwane z monokrystalicznych paneli dachowych zainstalowanych na budynku na Wydziale Elektrycznym, natomiast dane dotyczące obciążenia są zbierane z rezydencji na terenie kampusu. Pozostałe elementy modelu mikrosieci oparte są na literaturze i zostaną szczegółowo wyjaśnione. Układ modelu mikrosieci przedstawiono w postaci schematu jednokreskowego na rysunku 20. Składa się on z czterech modułów fotowoltaicznych o mocach szczytowych 12 kW, 15 kW, 6 kW i 15,9 kW w węzłach 2, 3, odpowiednio 4 i 4. W węzłach 2 i 5 znajdują się dwa identyczne zestawy DG o mocy 5,2 kW/6,5 kVA. LESS o pojemności 9,8 kWh znajduje się w węźle 3. Dodatkowo FC+HST, w skład którego wchodzi zbiornik magazynowania wodoru z równoważną pojemność 4,2 kWh znajduje się w węźle 5. Główna sieć w tym układzie służy jako rezerwowe źródło energii dla mikrosieci, zdolne do dostarczania i odbierania zarówno mocy czynnej, jak i biernej w zależności od potrzeb.



Rys. 20: Układ mikrosieci

Metryka LCOE (Levelized Cost of Energy) została wykorzystana w tym badaniu do porównania kosztów związanych z różnymi źródłami energii w mikrosieci. LCOE jest szeroko stosowany do

analizy porównawczej i pozwala na rzetelne porównanie opłacalności różnych technologii energetycznych, eliminując nieodłączne błędy. Bierze pod uwagę różne koszty ponoszone w okresie eksploatacji określonego generatora i zakłada całkowitą produkcję energii w celu obliczenia kosztu na jednostkę energii. Należy zauważyć, że LCOE nie uwzględnia instrumentów finansowych i ryzyka projektu i pozostaje statyczną miarą przez cały okres trwania projektu. Ponadto LCOE zależy od regionu, ponieważ produkcja energii ze źródeł odnawialnych w całym okresie eksploatacji jest różna w różnych obszarach geograficznych. Dlatego dokładność obliczeń LCOE jest najwyższa, gdy są wykonywane przez samych kierowników projektów, z uwzględnieniem lokalnych warunków i dostępności zasobów w określonej lokalizacji. Kalkulacja LCOE została przedstawiona poniżej:

$$LCOE = \frac{\sum_{t=0}^T C_t / (1+r)^t}{\sum_{t=0}^T E_t / (1+r)^t} \quad (3)$$

Kalkulacja LCOE uwzględnia całkowity koszt poniesiony w ciągu roku (C_t) i całkowitą energię wyprodukowaną w ciągu roku (E_t), z których oba są dyskontowane w czasie trwania projektu przy użyciu stopy dyskontowej (r). Czas trwania projektu oznaczony jest jako T , a brany pod uwagę rok to t . Należy zauważyć, że niektóre koszty początkowe nie są dyskontowane, ponieważ są wydatkami jednorazowymi jak w (9). Poniżej przedstawiono rozszerzoną wersję kalkulacji kosztów uwzględniającą różne składowe kosztów.

$$LCOE = \frac{C_c + I_c + \sum_{t=1}^T (F_c + O\&M_c) / (1+r)^t}{\sum_{t=1}^T E_t / (1+r)^t} \quad (10)$$

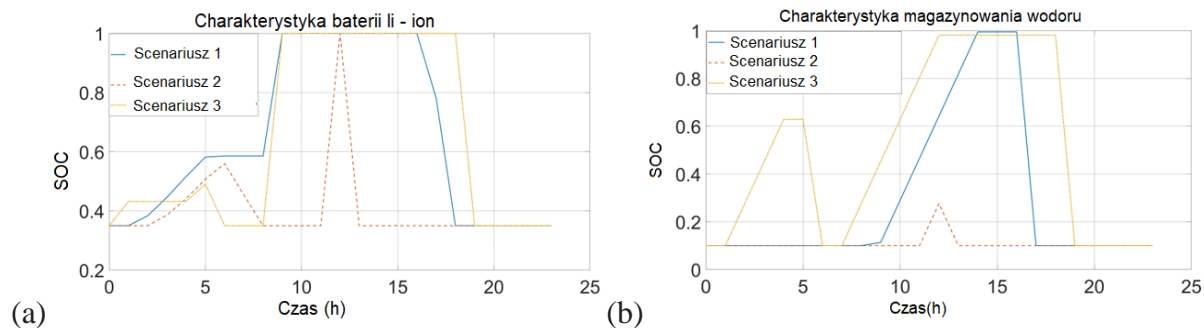
C_c reprezentuje koszt kapitału (jednorazowa płatność w tym badaniu), I_c oznacza koszt instalacji określonego generatora, F_c reprezentuje koszt zużytego paliwa (jeśli dotyczy), a $O\&M_c$ reprezentuje roczny koszt eksploatacji i konserwacji. Koszty związane z F_c i $O\&M_c$ są kosztami powtarzalnymi i są dyskontowane o stopę r . T odnosi się do czasu trwania projektu, podczas gdy t reprezentuje konkretny rok w czasie trwania projektu.

Na podstawie analizy danych obciążenia i odpowiednich danych dotyczących generacji można zidentyfikować trzy scenariusze:

- **Scenariusz 1 (jesień/wiosna):** W tym scenariuszu moc generowana w mikrosieci jest zbliżona do zapotrzebowania obciążenia.
- **Scenariusz 2 (zima):** W tym scenariuszu moc generowana w mikrosieci jest niższa niż zapotrzebowanie obciążenia.
- **Scenariusz 3 (lato):** W tym scenariuszu moc generowana w mikrosieci przekracza zapotrzebowanie obciążenia.

Działanie urządzeń magazynujących w mikrosieci przedstawiono na rysunkach 21a i 21b. Na rysunku 21a, dla Scenariusza 1, można zaobserwować, że urządzenie do przechowywania litowo-jonowego zostało naładowane około południa, kiedy produkcja energii w mikrosieci przekroczyła zapotrzebowanie na obciążenie. Następnie rozładowywał się wieczorem, gdy zapotrzebowanie na obciążenie przekraczało moc generowaną. Podobny wzór można zobaczyć dla urządzenia do

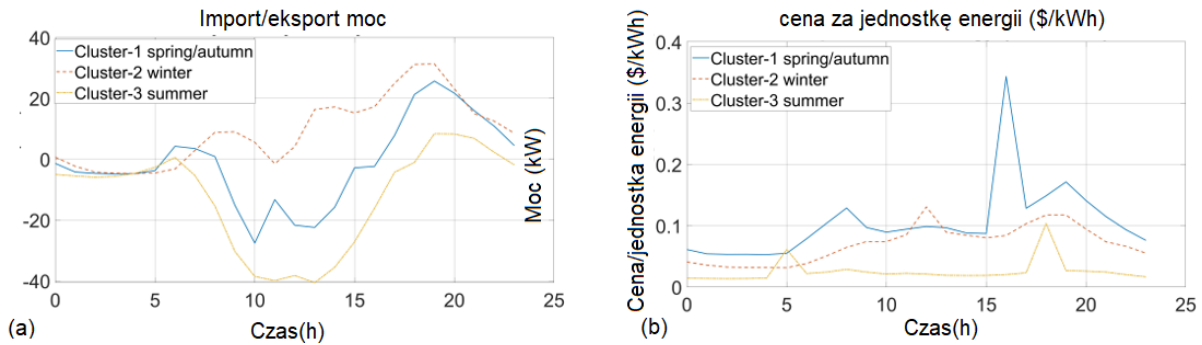
przechowywania wodoru na rysunku 8b dla Scenariusza 1. W Scenariuszu 2 działanie mikrosieci pokazuje, że akumulator litowo-jonowy w Scenariuszu 2 został naładowany do pełnej pojemności w południe, ale natychmiast się rozładował. W niektóre zimowe dni akumulator litowo-jonowy w ogóle się nie ładował, ponieważ zapotrzebowanie na obciążenie stale przekraczało wytwarzanie energii w mikrosieci. Zbiornik wodoru w Scenariuszu 2 został napełniony tylko częściowo, do 27% swojej pojemności, ze względu na ograniczoną dostępność nadwyżki energii netto w mikrosieci. W Scenariuszu 3 działanie mikrosieci ujawnia, że akumulator litowo-jonowy został naładowany do pełnej pojemności rano i nie rozładował się aż do wieczora. Było to spowodowane dużą generacją mocy mikrosieci w ciągu doby, która przekraczała zapotrzebowanie obciążenia. Magazyn wodoru osiągnął swoją maksymalną wydajność również w wyniku nadwyżki energii netto w mikrosieci.



Rys. 21: Ładowanie/rozładowanie: (a) system magazynowania baterii (b) system przechowywania wodoru.

Rysunek 22a przedstawia dynamiczną interakcję mikrosieci z siecią główną. Można wywnioskować, że dla Scenariusza 1 w południe, kiedy moc generowana w mikrosieci była wyższa niż zapotrzebowanie na obciążenie, moc była eksportowana do sieci głównej, natomiast wieczorem, gdy zapotrzebowanie na obciążenie było większe niż moc wyprodukowana, został sprowadzony. Rysunek 22b przedstawia sygnał cenowy w wyniku minimalizacji LCOE przez optymalizator i widać, że sygnał cenowy utrzymywał się poniżej 0,1 USD/kWh przez większą część dnia, z wyjątkiem sytuacji, gdy ogniwo paliwowe się rozładowało. Wynika to z faktu, że LCOE generatora opartego na wodorze jest znacznie wyższy w porównaniu z innymi. W przypadku Scenariusza 2 można zauważyć, że w przeciwieństwie do Scenariusza 1, w którym energia była eksportowana do sieci głównej w ciągu dnia, ze względu na duże obciążenie występował jedynie import energii z sieci głównej zapotrzebowania i niskiej podaży energii w mikrosieci. Sygnał cenowy dla Scenariusza 2 utrzymywał się poniżej 0,1 USD/kWh z wyjątkiem dwóch niewielkich skoków. W porównaniu ze Scenariuszem 1 skok jest mniejszy, ponieważ we wcześniejszym przypadku magazyn wodoru osiągnął pełną pojemność i ogniwo paliwowe pracowało dłużej, podczas gdy w tym scenariuszu ogniwo paliwowe pracowało krócej. W przypadku Scenariusza 3 można wywnioskować, że przez większą część dnia energia była eksportowana do głównej sieci ze względu na wysoką generację w mikrosieci. Fakt ten znajduje również odzwierciedlenie w sygnale cenowym, gdzie widać, że cena utrzymywała się blisko 0,02 USD/kWh, czyli najniższego poziomu dla wszystkich trzech scenariuszy. W tym scenariuszu

występują dwa skoki, które ściśle wskazują na działanie ogniwa paliwowego ze względu na jego wysoki LCOE.



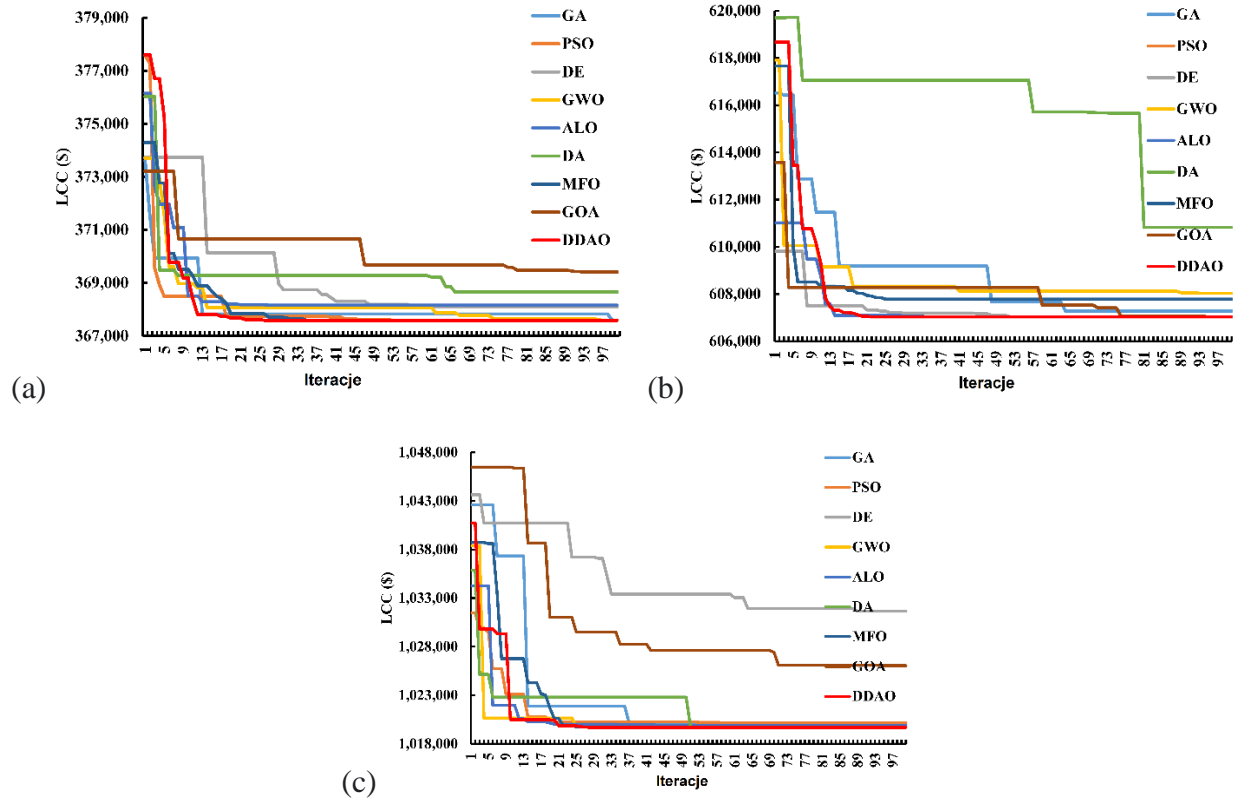
Rys. 22: (a) Interakcja mikrosieci z siecią główną (b) sygnał cenowy.

Podobne podejście do optymalizacji mikrosieci przedstawiono w pracy [3] z wyjątkiem implementacji MIDACO.

Praca [4] koncentruje się na procesie elektryfikacji odległych obszarów w Odisha w Indiach, gdzie zasilanie sieciowe nie jest dostępne. Odnawialne źródła energii były analizowane jako rozwiązanie, ale ich zależność od warunków pogodowych i czasu wymaga niezawodnego systemu magazynowania energii. Zbadano technologie akumulatorów niklowo-żelazowych (Ni-Fe), litowo-jonowych (Li-Ion) i kwasowo-ołowiowych (KO), aby wybrać najbardziej odpowiednią opcję. Modelowano trzy konfiguracje, a mianowicie PVP/BIOMG/BATTERY(Ni-Fe), PV/BIOMG/BATTERY(Li-Ion) i PVP/BMG/BATTERY(KO), wykorzystujące źródła energii fotowoltaicznej i biomasy. Konfiguracje te oceniono za pomocą dziewięciu algorytmów metaheurystycznych, przy czym konfiguracja PVP/BIOMG/BATTERY (Ni-Fe) osiągnęła optymalną wartość kosztu cyklu życia wynoszącą 367 586 USD. Spośród wszystkich algorytmów metaheurystycznych algorytm dynamicznej optymalizacji z wyżarzaniem różnicowym dał najlepsze wartości kosztu cyklu życia dla wszystkich trzech konfiguracji. W tym badaniu do analizy ekonomicznej zastosowano technikę kosztu cyklu życia (LCC). LCC został obliczony na podstawie początkowych kosztów kapitałowych, kosztów montażu, bieżącej wartości kosztów eksploatacji i konserwacji, bieżącej wartości kosztów odtworzenia i bieżącej wartości kosztów paliwa. Komponenty te zostały ocenione dla wszystkich komponentów systemu w celu oszacowania całkowitego kosztu cyklu życia.

Trzy wyżej wymienione konfiguracje zostały zoptymalizowane przy użyciu dobrze znanych algorytmów, takich jak Differential Evolutionary Algorithm (DE) [9], Genetic Algorithm (GA) [11], Moth Flame Optimization (MFO) [12], Dragonfly Algorithm (DA) [13], Optymalizacja roju cząstek (PSO) [14], Ant Lion Optimization (ALO) [15], Grey Wolf Optimization (GWO) [16], Grasshopper Optimization Algorithm (GOA) [17] i Dynamic Differential Annealed Optimization Algorithm [18]. Te algorytmy, które zostały uruchomione z ich domyślnymi wartościami parametrów kontrolnych z populacją i iteracjami, są uważane za równe 100.

Krzywe zbieżności dla trzech zaproponowanych w badaniu konfiguracji przedstawiono na rys. 23(a), rys. 23(b) i rys. 23(c)



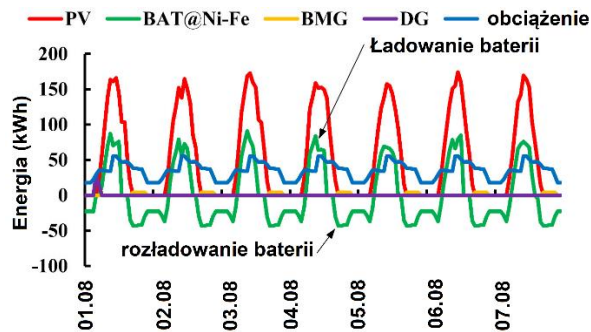
Rys. 23: Krzywe zbieżności (a) akumulatora Ni-Fe (b) akumulatora KO (c) akumulatora litowo-jonowego

Wyniki tego badania pokazują, że konfiguracja wykorzystująca technologię akumulatorów Ni-Fe wykazała najniższą wartość kosztu cyklu życia (LCC) wynoszącą 367 586 USD. W porównaniu z konfiguracjami wykorzystującymi akumulatory Li-Ion i LA, konfiguracja Ni-Fe wykazała znaczną redukcję LCC, z różnicami procentowymi odpowiednio 39% i 64%. Ponadto dokonano oceny optymalnej konfiguracji przy różnych wartościach prawdopodobieństwa utraty zasilania, w zakresie od 1% do 5%. Stwierdzono, że przy wartości prawdopodobieństwa utraty zasilania wynoszącej 1% zalecana jest konfiguracja optymalna do elektryfikacji badanego obszaru.

Praca wykonana w [5] jest podobna do pracy w [4] z następującymi ulepszeniami. Po pierwsze, druga praca koncentruje się na większej liczbie niepołączonych wiosek w stanie Odisha w Indiach, zapewniając bardziej szczegółową populację docelową i obszar w porównaniu z pierwszą pracą. Po drugie, proponuje autonomiczny zintegrowany hybrydowy system energii odnawialnej (IHRES) jako realne rozwiązanie, wykorzystujące dostępne zasoby energii odnawialnej na


badanym obszarze w celu zapewnienia dostępu do energii elektrycznej i słodkiej wody. Ponadto przedstawia sześć różnych konfiguracji z dwiema strategiami wysyłania i omawia ocenę scenariuszy zapotrzebowania na obciążenie z zarządzaniem po stronie popytu (DSM) i bez niego, oferując bardziej szczegółowy wgląd w modelowanie systemu. Ponadto druga praca wprowadza algorytm Salp Swarm i zawiera analizę wrażliwości uwzględniającą zmienne parametry wejściowe. Te ulepszenia poprawiają zrozumienie proponowanego rozwiązania, wydajności systemu i strategii optymalizacji w porównaniu z [4].

Model IHRES obejmuje różne źródła i obciążenia, w tym panele fotowoltaiczne, 3 różne rodzaje akumulatorów (litowo-jonowych, Ni-Fe i KO), generator biomasy, obciążenia rolnicze, obciążenia społeczne, takie jak szkoły, szpitale, oświetlenie uliczne i ładunki handlowe i przemysłowe. Aby zademonstrować odporność i skuteczność konwergencji w identyfikowaniu najlepszych globalnych wartości optymalnych, zaimplementowano następujące algorytmy optymalizacyjne: particle swarm optimization (PSO), differential evolutionary algorithm (DE), genetic algorithm (GA), ant lion optimization (ALO), grasshopper optimization algorithm (GOA), grey wolf optimization (GWO), moth flame optimization (MFO), and dragonfly algorithm (DA).




Rys 24: W ciągu jednego tygodnia sezonu letniego w sierpniu wydajność energetyczna różnych komponentów systemu IHRES opartego na akumulatorze Ni-Fe.

Rys. 24 i Rys. 25 przedstawiają wykresy zużycia energii różnych komponentów przez jeden tydzień, odpowiednio, w sezonie letnim i zimowym, dla IHRES opartego na akumulatorze Ni-Fe. Liczby pokazują, że panele fotowoltaiczne zaspokajają zapotrzebowanie na moc od rana do wieczora (od 8:00 do 16:00 zimą i od 7:00 do 17:00 latem). W tym czasie korzystne jest wykorzystanie nadwyżki energii generowanej przez panele fotowoltaiczne do ładowania baterii akumulatorów.



Rys. 25 W ciągu jednego tygodnia sezonu zimowego w styczniu, wydajność energetyczna różnych komponentów systemu IHRES opartego na akumulatorze Ni-Fe.

Głównym wkładem tej pracy [8] jest opracowanie opartego na logice rozmytej systemu zarządzania energią dla izolowanych mikrosieci. System ma na celu zapewnienie wydajnego przepływu mocy i sterowania między wieloma źródłami energii, systemami magazynowania energii i obciążeniami w mikrosieci. Wykazano, że proponowany regulator rozmyty znacznie skraca czas ładowania baterii w porównaniu z tradycyjnym sterowaniem przekaźnikowym i standardowym regulatorem PI.



Rys. 26: Ewolucja cyklu pracy dla czterech pętli sterowania.

Wyniki symulacji w MATLAB/Simulink pokazują skuteczność regulatora rozmytego w osiągnięciu optymalnej wydajności energetycznej. Ponadto specyfikacje kontrolera są oceniane w rzeczywistych przypadkach, co potwierdza jego zalety w zastosowaniach związanych z magazynowaniem energii oraz jego zdolność do zapewniania niezawodnego uzysku energii w różnych warunkach klimatycznych. Ogólnie rzecz biorąc, prace te oferują cenne rozwiązanie do zarządzania energią w izolowanych mikrosieciach, zwiększając efektywność energetyczną i wydajność systemu.

Charakterystyki współczynnika wypełnienia różnych metod sterowania, w tym sterowania przekaźnikowego, sterowania PI, sterowania neuronowego i sterowania rozmytego, przedstawiono na rysunku 26. Dynamikę ewolucji współczynnika wypełnienia można zaobserwować w sterowaniu rozmytym, sterowaniu siecią neuronową i sterowaniu PI pętlę, wskazujące ewolucję naładowania baterii. Natomiast pętla sterowania przekaźnikiem utrzymuje stały cykl pracy na poziomie 75%. Można jednak zauważyć niewielkie zakłócenia w sterowaniu przekaźnikowym i sterowaniu PI, gdy hybrydowe źródło energii przekracza wymaganą moc obciążenia. Sterowanie siecią neuronową wykazuje podobną wydajność do sterowania rozmytego, przy czym cykl pracy osiąga swoją maksymalną wartość.

Prace opisane w niniejszym wniosku zostały opublikowane przez autora i jego współautorów po dacie obrony doktoratu. O ile 9 prac mieści się w tytule wniosku o habilitację, o tyle jedna praca jest dość związana z dziedziną energii odnawialnej w postaci pojazdów elektrycznych, ale nie jest bezpośrednio związana z tytułem. Jest to opisane w następujący sposób.

Ten artykuł [10] przeglądowy dotyczący pojazdów elektrycznych obejmuje wiele aspektów tego tematu, w tym rozwój silnika trakcyjnego EV, przetwornice mocy do pojazdów elektrycznych, technologie komunikacyjne, technologie akumulatorów, technologie ładowania obejmujące szybkie ładowanie, ładowanie publiczne, wymianę akumulatorów i wyrównywanie naładowania akumulatorów. Uwzględnia również rolę pojazdów elektrycznych w handlu energią i bezpieczeństwie cybernetycznym. Jednym z wkładów wnioskodawcy było napisanie rozdziału o wymianie baterii. W tej części omówiono przeszkody społeczne napotymane przez właścicieli pojazdów elektrycznych, wyzwania i potencjalne korzyści systemów wymiany baterii (BSS) oraz różne rodzaje baterii stosowanych w BSS. Podkreśla również znaczenie prostoty i wygody w systemach ładowania, aby rozwiązać problemy związane z niepokojem związanym z zasięgiem pojazdów elektrycznych i zatorami. Omówiono względy ekonomiczne i zalety wymiany akumulatorów w porównaniu z tradycyjnymi metodami ładowania, a także potencjał BSS w zakresie zwiększenia niezawodności systemu elektroenergetycznego i skrócenia czasu oczekiwania. W dalszej części rozdziału wspomniano o modelowaniu działania BSS na rynku energii elektrycznej oraz eksploracji inteligentnych sieci i systemów pojazd-sieć (V2G). Odwołano się również do różnych badań i badań nad optymalizacją BSS, kosztami baterii i infrastrukturą wymiany baterii w różnych lokalizacjach. Sekcja dotycząca handlu energią, również napisana przez wnioskodawcę, zapewnia wgląd w zastosowania technologii blockchain w sektorze energetycznym, w szczególności w handlu energią i sieciach ładowania pojazdów elektrycznych (EV). W artykule zwrócono uwagę na ograniczenia istniejących systemów handlu energią opartych na technologiach wiedzy i komunikacji (ICT), które często są scentralizowane, niepewne

i zawodne. W przeciwieństwie do tego, blockchain ma potencjał do zwiększenia wydajności, przejrzystości, wiarygodności i identyfikowalności w procesach handlu energią pojazdów elektrycznych. Umożliwia pojazdom elektrycznym obliczanie szybkości rozładowywania akumulatorów, lokalizowanie renomowanych stacji ładowania energii, szacowanie zapotrzebowania na energię, określanie optymalnych tras dostaw energii oraz obliczanie cen energii w określonych regionach. Co więcej, blockchain oferuje zwiększoną przejrzystość wszystkim uczestnikom sieci. Jednak istniejące podejścia są nadal ograniczone i nie odpowiadają szerszym potrzebom rynku, szczególnie w zakresie metod płatności, które muszą zapewniać bezpieczeństwo, wygodę i uniwersalność. Niektóre wysiłki badawcze koncentrowały się na koordynacji ładowania na poziomie mieszkania, integracji i odporności sieci ładowania w Internecie pojazdów elektrycznych (IoEV) oraz wykorzystaniu blockchain do bezpiecznego zdecentralizowanego przechowywania danych w aplikacjach sieci motoryzacyjnych. Ponadto badanie dotyczy handlu opartego na współpracy i handlu frakcyjnego na rynkach energii typu peer-to-peer.

Prowadzone przez Habilitanta prace nad wykorzystaniem modeli sztucznej inteligencji/uczenia maszynowego do prognozowania mocy wyjściowej fotowoltaiki, zapotrzebowania obciążenia i kierunku przepływu mocy w klastrze energii wraz z wykorzystaniem algorytmów optymalizacyjnych do inteligentnego zarządzania rozproszonymi źródłami energii we wskazanych w serii publikacji mieszczą się w zakresie dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne.

Aby poradzić sobie z nieprzewidywalnością mocy wyjściowej z paneli fotowoltaicznych, habilitanta wpadła na pomysł wykorzystania modeli głębokiego uczenia opartych na AI/ML do prognozowania przyszłych mocy wyjściowych w [1]. Metodologia obejmowała wybór odpowiedniego typu modelu głębokiego uczenia się, który może wydajnie pracować z danymi szeregowych czasowych i rozumieć zależności czasowe w danych. W tym przypadku wybrano autoenkoder LSTM. Co więcej, habilitanta również wniosła swój wkład, implementując te modele w Pythonie i sprawdzając ich działanie na zbiorze danych. Analiza formalna została przeprowadzona poprzez wizualizację wyników, a kandydat był również odpowiedzialny za wybór odpowiednich miar dokładności, którymi w tym przypadku były RMSE, MAE i BIAS. Habilitant był również odpowiedzialny za napisanie oryginalnego manuskryptu i ustosunkowanie się do uwag recenzentów. Był również odpowiedzialny za utrzymywanie kontaktu z zastępcą redaktora naczelnego czasopisma jako autorem korespondencyjnym.

W celu zapewnienia optymalnej kombinacji rozproszonych źródeł energii dla minimalizacji kosztów eksploatacji habilitantka wpadła na pomysł wykorzystania inteligentnych algorytmów optymalizacji w [2]. Metodologia sformułowana przez wnioskodawcę obejmowała eksplorację metaheurystyk, takich jak MIDACO i PSO, jak opisano wcześniej. Habilitant zamodelował również mikrosieć i zaimplementował algorytm optymalizacyjny w Matlabie. Przeprowadził również walidację i analizę formalną, badając wydajność badanych algorytmów, badając i porównując ostateczne zminimalizowane koszty operacyjne i szybkość konwergencji. Habilitant był odpowiedzialny za napisanie oryginalnego manuskryptu i ustosunkowanie się do uwag recenzenta. Wnioskodawca zarządzał również wizualizacjami zawartymi w artykule i pełnił funkcję autora korespondencyjnego.

W celu zapewnienia optymalnej koordynacji rozproszonych źródeł energii dla minimalizacji kosztów w mikrosieci wkład habilitatora jest wielopłaszczyznowy w [3]. Wprowadził koncepcję wykorzystania inteligentnych algorytmów optymalizacyjnych do efektywnej alokacji rozproszonych zasobów energii i określenia najniższych kosztów eksploatacji. Wiązało się to z badaniem metaheurystycznych algorytmów optymalizacji, ze szczególnym uwzględnieniem nowo opracowanego Optymalizatora Politycznego i Algorytmu Lichtenberga. Dodatkowo zaprogramował model mikrosieci i algorytm optymalizacyjny w MATLAB-ie. Wnioskodawca przeprowadził również analizę formalną, wykreślając wyniki i oceniając skuteczność wszystkich badanych podejść. Ponadto habilitator wcielił się w rolę autora korespondencji i przyczynił się do wizualnego przedstawienia rycin użytych w artykule.

W celu określenia najodpowiedniejszej technologii magazynowania baterii dla proponowanej mikrosieci habilitantka przeprowadziła kompleksowe badania mające na celu znalezienie równań dla trzech rodzajów akumulatorów: nikielowo-żelazowych (NiFe), litowo-jonowych (Li-Ion) oraz kwasowo-ołowiowych (LA) w [4]. Dodatkowo habilitantka aktywnie uczestniczyła w adresowaniu części recenzji. Zajmowali się oni zarządzaniem zasobami danych dostarczonych dla wytwórców energii odnawialnej, w tym gromadzeniem i czyszczeniem danych oraz świadczeniem usług przetwarzania w chmurze w celu zwiększenia mocy obliczeniowej naszego partnera. Ponadto odegrały rolę w wizualizacji figur użytych w artykule. Wreszcie, habilitant był także autorem korespondencyjnym w całym procesie badawczym.

Wkład habilitanta obejmuje różne aspekty, w tym kurację danych, w ramach której zebrano dane z różnych źródeł, a następnie je oczyszczono i uporządkowano, w tym generatory i obciążenia wykorzystywane w hybrydowym systemie energii odnawialnej w [5]. Ponadto habilitant odegrał kluczową rolę w modelowaniu i podejmowaniu decyzji, w szczególności dotyczących stosowania wskaźników analizy kosztów, takich jak koszt bieżący netto i koszt cyklu życia. Ponadto aktywnie uczestniczyli jako autorzy korespondencji w całym procesie badawczym.

Na wkład habilitanta w pracę [6] składa się szeroki zakres zadań, w tym tworzenie oprogramowania do programowania modeli głębokiego uczenia w języku Python. W tym konkretnym przypadku model LSTM wariantów CNN-LSTM i LSMT-CNN. Odpowiadali oni za walidację i zapewnienie prawidłowego funkcjonowania zaprogramowanych modeli. Dokonano tego za pomocą wskaźników dokładności, takich jak RMSE, MAE i BIAS. Dodatkowo habilitantka przeprowadziła analizy formalne sprawdzające solidność modeli, uruchamiając je wielokrotnie i wykorzystując testy statystyczne do oceny spójności wyników. Starannie reagowali na uwagi recenzentów w trakcie procesu recenzji. Ponadto, jako opiekun asystenta autora, zapewniali wskazówki i wsparcie w trakcie badań. Ostatecznie habilitant administrował projektem, w tym organizował finansowanie publikacji rękopisu.

Wkład habilitanta w pracę [7] polega na udzielaniu wsparcia i wskazówek autorowi wiodącemu, jako że kandydat pełnił funkcję promotora autorskiego pomocniczego. Po drugie, habilitant wdrożył model LSTM Autoencoder, uznając jego doskonałą wydajność w rejestrowaniu relacji czasowych w dostarczonych danych. Wreszcie habilitant sprawnie zarządzał projektem, dbając o przygotowanie finansowe niezbędne do wydania manuskryptu.

Wkład habilitatora w [8] obejmuje sformułowanie metodologii modelowania autonomicznych mikrosieci. Po drugie, przeprowadzili dogłębne badanie w celu zidentyfikowania zarządzania energią opartego na pętli, ze szczególnym uwzględnieniem logiki rozmytej jako skutecznego podejścia do minimalizowania czasu ładowania baterii spośród kilku dostępnych metod. Wreszcie habilitantka z powodzeniem zapewniła finansowanie projektu.

Wkład habilitatora obejmował różne aspekty badań w [9]. Opracowali koncepcję wykorzystania modeli głębokiego uczenia się do przewidywania zapotrzebowania na obciążenie fabryki i dopracowali dane, przeprowadzając czyszczenie i wstępne przetwarzanie danych. Habilitant przeprowadził analizy formalne za pomocą narzędzi statystycznych, aby zrozumieć

zapotrzebowanie na obciążenia fabryki w ciągu roku i wielu lat. Zaproponowali metodologię obejmującą dekompozycję trybu wariacyjnego wraz z modelami hybrydowymi, takimi jak CNN-GRU i CNN-LSTM. Dodatkowo habilitant był zaangażowany w tworzenie oprogramowania, w tym programowanie modeli, pisanie oryginalnego manuskryptu oraz pomoc w odpowiadaniu na uwagi recenzentów. Wreszcie aktywnie zarządzali zasobami projektu, co wiązało się z przetwarzaniem danych i generowaniem wizualizacji wyników.

Wkład habilitatora w [10] obejmuje konceptualizację, metodologię, analizę formalną, badania, zarządzanie zasobami, napisanie oryginalnego manuskryptu, ustosunkowanie się do uwag recenzentów oraz wizualizację części pracy przeglądowej związanej z technologiami ładowania i handlu energią. Obejmuje to przegląd metod szybkiego ładowania, ładowania nocnego, ładowania flash i ładowania trasy. Dodatkowo obejmuje przegląd wymiany baterii. Sekcja obrotu energią prowadzi przegląd metod taryfowania i handlu peer-to-peer

Podsumowanie prac badawczych Habilitanta w liczbach

Liczba publikacji (sumaryczny Impact Factor wszystkich prac Habilitanta: 73.742):

- Artykuły opublikowane w czasopiśmie posiadających wskaźnik Impact Factor: 20.
- Artykuły opublikowane w czasopiśmie nie posiadających wskaźnika Impact Factor: 8.
- Opublikowane referaty na konferencjach krajowych i międzynarodowych: 7.

W tym liczba publikacji:

- Jednoautorskich: 2.
- Dwuautorskich i trzyautorskich: 7.
- Czteroautorskich i pięcioautorskich: 11.
- Sześćoautorskich i więcej: 15.

Po uzyskaniu stopnia doktora:

- Sumaryczny Impact Factor prac: 42,696.
- Suma punktów MNiSW przyznanych za artykuły w czasopiśmie po uzyskaniu stopnia doktora: 1360.

Czasopismo	Liczba artykułów	Wskaźnik Impact Factor	Punkty MNiSW	Suma punktów MNiSW
IEEE Access	1	3,476	100	100
Applied Soft Computing	1	8,263	200	200
Electronics	2	5,380	100	200
Energies (2021)	2	3,252	140	280
Energies (2022)	2	3,200	140	280
Sustainability	1	3,889	100	100
Sensors	1	3,847	100	100
Energy Reports	1	4,937	100	100
Renewable Energy & Power Quality Journal	1	-	20	20
Przegląd Elektrotechniczny	1	-	70	70
Applied System Innovation	1	-	20	20
Łącznie	14	-	-	1470

5. Informacja o wykazywaniu się istotną aktywnością naukową albo artystyczną realizowaną w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej

Jeśli chodzi o współpracę z zagraniczną instytucją naukową, habilitant ma wieloletnią współpracę naukową z prof. Josepem Guerrero z Centre for Research in Microgrids (CROM) z Aalborg University. Współpraca rozpoczęła się w 2019 r., a w 2020 r. habilitant odbył roczny staż naukowy w CROM dotyczący systemów zarządzania energią w mikrosieciach z predyktorami głębokiego uczenia. Współpraca zaowocowała 3 artykułami, które zostały opublikowane w czasopiśmie o wysokim współczynniku wpływu, z czego jeden artykuł został opublikowany w czasopiśmie 200-punktowym. Ponadto, po dyskusji z naukowcami z CROM. Powstały pomysły, które habilitant wykorzystał do złożenia wniosku projektowego w konkursie Miniatura - 6, który ostatecznie otrzymał dofinansowanie i umożliwił kolejny 68-dniowy wyjazd do CROM na wykorzystanie swoich laboratoriów na symulatorach mikrosieci czasu rzeczywistego. Załączniki dotyczące przeprowadzonych staży naukowych znajdują się w ostatniej części wniosku, a prace opublikowane w wyniku tej współpracy to.

Zał. 1 Potwierdzenie: Roczny staż naukowy w ramach programu Erasmus+

Zał. 2 Potwierdzenie: 68 dniowy staż naukowy w ramach Miniatury - 6 grantów.

- [1] Microgrid energy management using metaheuristic optimization algorithms.
Applied Soft Computing (MNiSW: 200 pkt., IF: 8,263). 2023, vol. 134, art. 109981, s. 1-18.
- [2] Optimal location of an electrical vehicle charging station in a local microgrid using an embedded hybrid optimizer.
International Journal of Electrical Power & Energy Systems (MNiSW: 100 pkt., IF: 5.659). 2021, vol. 131, art. 106979, s. 1-10.
- [3] Microgrid energy management system with embedded deep learning forecaster and combined optimizer.
IEEE Access (MNiSW: 100 pkt., IF: 3.367). 2020, vol. 8, s. 202225-202239.

Ważną współpracą habilitanta jest Vellore Institute of Technology, kampus Vellore i Chennai w Indiach. Natomiast oba kampusy można traktować jako osobne kolaboracje ze względu na ich niezależny charakter funkcjonowania. W tej aplikacji osiągnięcia obu zostaną połączone. Współpraca zaowocowała łącznie 4 publikacjami, które uzyskały łącznie 320 punktów. Czasopisma, w których zostały opublikowane, to Electronics, IEEE Access, Applied System Innovation i Energy Reports. Habilitant jest również współpromotorem doktoranta w Vellore Institute of Technology, kampus Chennai. Jest zatrudniony jako wizytujący adiunkt z 15 godzinami dydaktyki rocznie online/osobiście również w kampusie Chennai. Brał również udział jako gościnny mówca w międzynarodowych warsztatach prowadzonych przez kampus Vellore. Wreszcie, wraz z dr B Sri Revathi z kampusu w Chennai, złożono podanie do konkursu Wadźry,

którego gospodarzem była Rada Badań Nauki i Inżynierii (SERB), Indie. Poniżej wymieniono załączniki związane ze współpracą oraz wspólne publikacje.

Zał. 3 Potwierdzenie: Mianowanie na stanowisko promotora pomocniczego Pani T. ANUSHALINI (doktorant) w Vellore Institute of Technology, Chennai, Indie.

Zał. 4 Potwierdzenie: Mianowanie na adiunkta 15 godzin rocznie nauczania w Vellore Institute of Technology, Chennai, Indie.

Zał. 5 Potwierdzenie: Zaproszony prelegent na Virtual International Higher-End Workshop on Electric Vehicle Intelligent Technologies, Vellore Institute of Technology, Vellore, India.

Zał. 6 Potwierdzenie: Współpraca przy składaniu propozycji projektu o nazwie SOLARFLEX na wezwanie Wadźry prowadzone przez SERB.

- [1] Probabilistic LSTM-Autoencoder based hour-ahead solar power forecasting model for intra-day electricity market participation: A Polish case study.
IEEE Access (MNiSW: 100 pkt., IF: 3,476), 2022, vol. 10, s. 110628-110638.
- [2] A review on electric vehicle: technologies, energy trading, and cyber security.
Energy Reports (MNiSW: 100 pkt., IF: 4,937). 2022, vol. 8, s. 9662-9685.
- [3] Intelligent fault detection in Hall-Effect rotary encoders for industry 4.0 applications.
Electronics (MNiSW: 100 pkt., IF: 2,690). 2022, vol. 11, nr 21, art. 3633, s. 1-17.
- [4] Analyzing the electronics of image sensors and their functionality to develop low light-emitting source image.
Applied System Innovation (MNiSW: 20 pkt). 2022, vol. 5, nr 5, art. 100, s. 1-19.

Uniwersytet w Palermo we Włoszech to kolejna instytucja, z którą habilitantka dobrze współpracuje w zakresie prowadzenia corocznych wykładów na zaproszenie. Wykłady te były realizowane w ramach umów o nauczanie Erasmus+.

W 2022 roku zrealizowano łącznie 8 godzin wykładów w ciągu 5 dni od 23.05.2022 do 27.05.2022. W 2023 roku zrealizowano łącznie 8 godzin wykładów w ciągu 5 dni od 22.05.2023 do 26.05.2023.

Zał. 7 Potwierdzenie: Prowadzenie wykładów na zaproszenie na Uniwersytecie w Palermo w ramach umowy o nauczanie Erasmus+.

Poza wyżej wymienionymi ważniejszymi współpracami habilitant ma na swoim koncie pomniejszych współpracę z kilkoma naukowcami z różnych części świata. Zawierają:

- Brandenburg University of Technology Cottbus-Senftenberg, Germany.
- TU Delft, The Netherlands.
- GMR Institute of Technology, India.
- Griffith University, Australia.
- Engineering Institute of Technology, Australia.
- VSB—Technical University of Ostrava, Czech Republic.
- Northern Border University, Saudi Arabia.
- University of Gabès, Tunisia.
- King Saud University, Saudi Arabia.
- Taif University, Saudi Arabia.

- [1] *Political-optimizer-based energy-management system for microgrids.*
Electronics (MNiSW: 100 pkt., IF: 2,690). 2021, vol. 10, nr 24, art. 3119, s. 1-18.
- [2] *Off-grid rural electrification in India using renewable energy resources and different battery technologies with a dynamic differential annealed optimization.*
Energies (MNiSW: 140 pkt., IF: 3,252). 2021, vol. 14, nr 18, art. 5866, s. 1-21.
- [3] *Optimal operation of an integrated hybrid renewable energy system with demand-side management in a rural context.*
Energies (MNiSW: 140 pkt., IF: 3,252). 2022, vol. 15, nr 14, art. 5176, s. 1-50.
- [4] *CNN-LSTM vs. LSTM-CNN to predict power flow direction: a case study of the high-voltage subnet of Northeast Germany.*
Sensors (MNiSW: 100 pkt., IF: 3,847). 2023, vol. 23, nr 2, art. 901, s. 1-20.
- [5] *Multistep forecasting of power flow based on LSTM autoencoder: a study case in regional grid cluster proposal.*
Energies (MNiSW: 140 pkt., IF: 3,2). 2023, vol. 16, nr 13, art. 5014, s. 1-20.
- [6] *Decreasing the battery recharge time if using a fuzzy based power management loop for an isolated micro-grid farm.*
Sustainability (MNiSW: 100 pkt., IF: 3,889). 2022, vol. 14, nr 5, art. 2870, s. 1-21.
- [7] *Analyzing the electronics of image sensors and their functionality to develop low light-emitting source image.*
Applied System Innovation (MNiSW: 20 pkt.). 2022, vol. 5, nr 5, art. 100, s. 1-19.

6. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę lub sztukę.

Działalność dydaktyczna Habilitanta obejmuje prowadzenie zajęć dydaktycznych na uczelni, promowanie prac inżynierskich i magisterskich, Habilitant prowadził lub obecnie prowadzi na Politechnice Wrocławskiej następujące zajęcia dydaktyczne:

- Wykład: Circuits and Systems,
- Wykład: Industrial Ecology Selected Problems,
- Wykład: Matematyka (kurs przygotowawczy dla studentów zagranicznych)
- Wykład: Informatyka (kurs przygotowawczy dla studentów zagranicznych)
- Wykład: Fizyka (kurs przygotowawczy dla studentów zagranicznych)
- Ćwiczenia: Podstawy elektrotechniki,
- Ćwiczenia: Wybrane zagadnienia teorii obwodów,
- Ćwiczenia: Circuits and systems,
- Laboratorium: Obwody elektryczne,
- Laboratorium: Teoria obwodów 2,
- Laboratorium: Ogniwa fotowoltaiczne,
- Laboratorium: Podstawy elektrotechniki 2.

W Vellore Institute of Technology w Chennai habilitant prowadził następujące kursy.

- Distributed Generation and Microgrid.
- Energy management systems and SCADA.

Habilitant jako promotor prac dyplomowych na studiach I i II stopnia prowadził następujące tematy prac:

- *Short term solar forecasting using AI deep learning technology.*
- *Analiza kosztów i korzyści systemu zarządzania energią w domu.*
- *Inteligentna stacja ładowania pojazdów elektrycznych.*
- *Solution for engineering and testing of ground fault protection in distribution systems.*
- *Data science for power systems: day ahead solar forecasts.*
- *Microgrid modelling and operation optimization in Python.*
- *Exploration of AI/ML algorithms for short term hour ahead solar forecasts.*
- *Analiza kosztów i korzyści systemu zarządzania energią w domu.*
- *Redukcja śladu węglowego w przemyśle, poprzez wprowadzenie ulepszonych rozwiązań oświetlenia.*

- *Oddziaływanie źródeł oświetleniowych na parametry energii elektrycznej.*

Habilitant jest również promotorem pominiczym dla kolejnych studentów.

- Mgr. inż. Fachrizal Aksan – Wydział Elektryczny – Politechnika Wroclawska (**Zał. 8**).
- Mgr. inż. T. Anushalini – School of Electrical Engineering – Vellore Institute of Technology, Chennai (**Zał. 3**).

Do działań organizacyjnych Habilitanta należą przede wszystkim:

- Członek komitetu nagrody Lema na Politechnice Wroclawskiej.
Nagroda Lema została ustanowiona dla upamiętnienia setnej rocznicy urodzin wielkiego polskiego wizjonera i powieściopisarza fantastyki naukowej Stanisława Lema, który w 1981 roku otrzymał tytuł doktora honoris causa Techniki Wroclawskiej. Istotne elementy spuścizny literackiej Lema: ludzie, nauka, technologia, postęp i przyszłość – są jednocześnie kluczowymi elementami określającymi misję i aspiracje Wrocław Tech. Nagroda Lema przyznawana jest corocznie jednemu młodemu naukowcowi, którego twórcza praca naukowa lub inżynierska może pozytywnie wpłynąć na przyszłość cywilizacji coraz bardziej nasyconej technologią.
- Kierownik facebookowej strony Akademii Iuvenum Politechniki Wroclawskiej.
Academię Iuvenum (AI) tworzą młodzi naukowcy Politechniki Wroclawskiej (co najmniej rok po doktoracie), którzy realizują z sukcesem projekty badawcze. To elitarne grono, które sprawuje kadencję przez dwa lata. Jego zadaniem jest podejmowanie różnych inicjatyw na rzecz uczelni, stworzenie platformy służącej wymianie myśli naukowej, a także umożliwienie młodym naukowcom wyrażania opinii wewnątrz i na zewnątrz uczelni

Do działalności popularyzującej naukę Habilitanta należą m.in.:

- Redaktor gościnny wydania specjalnego „Modeling, Simulation, and Analysis of Electrical Power Systems” w MDPI Mathematics (MNIŚW: 100 pkt., IF: 2,4). (**Zał. 9**)
- Jest stałym recenzentem konferencji "IEEE International Conference on Environment and Electrical Engineering and IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)". Przed uzyskaniem stopnia doktora zrecenzował łącznie 6 artykułów na konferencji EEEIC 2020, 10 artykułów na konferencji EEEIC 2021. Po uzyskaniu stopnia doktora zrecenzował 3 artykuły na konferencji EEEIC 2022 i 7 artykułów na konferencji EEEIC 2023. (**Zał. 10**)
- Prace recenzyjne dotyczące publikacji w czasopiśmie można podsumować w następujący sposób. Liczba recenzowanych prac w czasopiśmie naukowych w latach 2020 - 2023 wynosi 27

Czasopismo	Lista filadelfijska	Liczba artykułów	Rok
Mathematics	Tak	2	2023
Energies	Tak	1	2023
Machines	Tak	1	2023
Axioms	Tak	1	2023
Energies	Tak	5	2022
Electronics	Tak	2	2022
Mathematics	Tak	3	2022
World Electrical Vehicle Journal	Tak	1	2022

Sensors	Tak	1	2022
Applied Sciences	Tak	1	2022
Network: computation in Neural Systems	Tak	1	2022
IEEE Access	Tak	2	2022
Clean Energy OUP	Tak	1	2021
Sustainability	Tak	1	2021
Processes	Tak	1	2021
IET Generation, Transmission & Distribution	Tak	1	2021
IEEE Access	Tak	1	2020
IET Renewable Power Generation	Tak	1	2020

- Przeprowadzenie wykładów zaproszonych:
 - 23.05.2022 – 27.05.2022, Palermo University, Palermo, Włochy, nauczanie części przedmiotu Smart Grid na uczelni na zaproszenie profesora prowadzącego kurs w ramach programu mobilności dydaktycznej Erasmus. **(Zał. 7)**
 - 22.05.2023 do 26.05.2023, Palermo University, Palermo, Włochy, nauczanie części przedmiotu Smart Grid na uczelni na zaproszenie profesora prowadzącego kurs w ramach programu mobilności dydaktycznej Erasmus. **(Zał. 7)**
 - 23.11.2020, Global Academy of Technology, Bengaluru, Indie. Temat: “Deep learning networks for solar energy forecasting and metaheuristics for energy management in microgrids”. **(Zał. 11)**
 - 22.10.2021, AMRITA School of Engineering, Chennai, Indie. Temat: “Microgrid energy management systems with hybrid optimizers, embedded deep learning forecasters and e-vehicle charging stations”. **(Zał. 12)**
 - 19.04.2021, Vellore Institute of Technology, School of Electrical Engineering. Temat: “Role of IoT and Machine Learning in Electrical Engineering”. **(Zał. 13)**
 - 12.07.2023, Vellore Institute of Technology, School of Electrical Engineering, Virtual, International Higher-End Workshop on Electric Vehicle Intelligent Technologies. Temat: “Deep learning for Power Systems”. **(Zał. 5)**

7. Nagrody

- Nagroda Rektora Politechniki Wrocławskiej: 2022.
Nagroda Rektora Politechniki Wrocławskiej została przydzielona Habilitantowi w uznaniu za wyróżniający wkład w działalność uczelni.
- Laureat konkursu Politechniki Wrocławskiej „Primus” dla autorów wybitnych publikacji naukowych: 2023
Program Primus ustanowiony został przez JM Rektora Politechniki Wrocławskiej. Program skierowany jest do wszystkich pracowników naukowych a jego założeniem jest aktywizowanie społeczności akademickiej poprzez premiowanie najwyżej punktowanych publikacji w całej uczelni a także publikacji przyczyniających się do wzrostu punktacji ewaluowanych w uczelni dyscyplin naukowych. Habilitant został nagrodzony w ramach działania II: premiowanie publikacji istotnie przyczyniających się do wzrostu punktacji ewaluowanych w uczelni dyscyplin naukowych.

- Laureat konkursu „Secundus” dla młodych naukowców z najlepszym dorobkiem publikacyjnym: 2021, 2022.

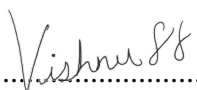
Program Secundus ustanowiony został przez JM Rektora Politechniki Wrocławskiej. Celem programu jest wyróżnienie 100 młodych naukowców PWr z najlepszym dorobkiem publikacyjnym w danym roku kalendarzowym.

- Laureat konkursu „Academia Iuvenum” dla najlepszych 24 młodych naukowców Politechniki Wrocławskiej: 2022. **(Zał. 14)**

Academia Iuvenum powołana przez JM Rektora Politechniki Wrocławskiej i stanowi jeden z elementów działania Politechniki Wrocławskiej zmierzających do promowania doskonałości naukowej w uczelni. Nadrzędnym celem przedsięwzięcia jest wyłonienie i wspieranie rozwoju grupy wybitnych młodych naukowców w różnych dyscyplinach naukowych. Przeznaczeniem Academia Iuvenum jest także pełnienie roli platformy służącej do interdyscyplinarnej wymiany intelektualnej. W danym roku wybieranych jest jedynie dwudziestu czterech członków Akademii Iuvenum.

Podsumowując aktywność naukową, działania dydaktyczne, organizacyjne oraz popularyzujące naukę, do najważniejszych elementów można zaliczyć:

- Artykuły opublikowane w czasopismach posiadających wskaźnik Impact Factor: 20.
- Artykuły opublikowane w czasopismach nie posiadających wskaźnika Impact Factor: 8.
- Opublikowane/wygłoszone referaty na konferencjach krajowych i międzynarodowych: 7.
- Sumaryczny Impact Factor prac: 73,742, w tym opublikowanych po uzyskaniu stopnia doktora 42,696.
- Suma punktów MniSW przyznanych za publikację po uzyskaniu stopnia doktora: 1360.
- Wygłoszone wykłady zaproszone na uczelniach zagranicznych: 6.
- Kierowanie projektami badawczymi: 1.
- Udział w projektach badawczych jako wykonawca: 2.
- Promotorstwo prac inżynierskich i magisterskich: 10.
- Promotorstwo prac doktorskich (promotor pomocniczy): 2
- Recenzowanie referatów dla konferencji międzynarodowych: 20.
- Recenzowanie artykułów w czasopismach naukowych: 27.
- Nagroda Rektora Politechniki Wrocławskiej: 1.
- Laureat konkursów Politechniki Wrocławskiej: „Primus” oraz dwukrotnie „Secundus” dla naukowców z najlepszym dorobkiem publikacyjnym.
- Członek „Academia Iuvenum” dla najlepszych młodych naukowców Politechniki Wrocławskiej.

.....


(Podpis)