



**Hybrydowy System Zasilania, wykorzystujący metody sztucznej
inteligencji, do optymalizacji pracy lokalnego systemu
elektroenergetycznego wyposażonego w źródła OZE
i magazyny energii**

mgr inż. Bartłomiej Borkowski

Praca doktorska

Promotor:

dr hab. inż. Piotr Szulc, prof. uczelni

Wrocław, 2026

Praca doktorska zrealizowana w ramach programu „Doktorat wdrożeniowy II - sztuczna inteligencja” edycja V na podstawie umowy DWD/5/0311/2021 pomiędzy Ministerstwem Edukacji i Nauki oraz Politechniką Wrocławską.

Najbliższym: Katarzynie i Janowi

STRESZCZENIE

Celem rozprawy doktorskiej było opracowanie i walidacja autorskiego algorytmu sterowania magazynowania energii zintegrowanego ze źródłami energii odnawialnej, czyli Hybrydowym Systemem Zasilania (HES). Zadaniem opracowanego algorytmu, opartego na zaproponowanej funkcji celu, była optymalizacja wykorzystania energii zgromadzonej w magazynie na potrzeby własne lub na jej wymianę z siecią, w celu uzyskania najwyższej ceny sprzedaży. Jako dane wejściowe wykorzystano zarówno dane meteorologiczne, jak i informację o zmienności cen energii. Do optymalizacji pracy magazynu zaproponowano podejście hybrydowe wykorzystujące sztuczne sieci neuronowe typu LSTM i algorytm genetyczny (GA) ze zmodyfikowaną procedurą inicjalizacji populacji. Jako warunki początkowe, algorytm genetyczny (GA) wykorzystuje wyniki otrzymane z rozwiązania algorytmu opartego na regułach (RB). Jak się okazuje, to podejście pozwala na szybsze opracowanie optymalnego harmonogramu pracy magazynu energii w jednodniowym horyzoncie czasowym (Day-Ahead), poprzez eliminację ryzyka początkowej losowości rozwiązań.

Do zrealizowania celu pracy opracowano model matematyczny hybrydowego systemu zasilania złożonego z instalacji fotowoltaicznej, turbiny wiatrowej, magazynu energii i lokalnego obciążenia. W pierwszym etapie porównano skuteczność działania opracowanego algorytmu (GA) z klasycznym sterowaniem opartym na regułach (RB). Do przeprowadzenia symulacji wykorzystano rzeczywiste dane meteorologiczne oraz dynamikę cen z 15-minutową rozdzielczością dla jednego pełnego roku kalendarzowego. Analiza otrzymanych wyników wykazała, że zastosowanie zaproponowanego algorytmu genetycznego pozwala uzyskać większe korzyści ekonomiczne w stosunku do metody RB, nawet po uwzględnieniu kosztów zużycia magazynu. Wykazano również zdecydowane korzyści wynikające ze wzrostu liczby cykli ładowania i rozładowania magazynu energii, spowodowane inteligentnym arbitrażem cenowym. Jest to ekonomicznie uzasadnione i zdecydowanie przewyższa strategię oparte wyłącznie na wykorzystaniu energii na potrzeby własne. Przeprowadzona analiza wrażliwości wykazała, że oprócz danych meteorologicznych i dynamiki cen energii, również pojemność magazynu oraz stan jego naładowania na koniec dnia, są kluczowymi parametrami, które należy brać pod uwagę.

W kolejnym etapie przeprowadzono walidację działania zaproponowanego algorytmu sterowania wykorzystując dane zebrane z obiektu rzeczywistego. Również w tym przypadku, otrzymane wyniki wyraźnie wskazują, że zaproponowany autorski algorytm harmonogramowania pracy magazynu wpływa na znaczący wzrost zysków ekonomicznych dzięki możliwości wdrożenia dynamicznego arbitrażu cenowego, czego nie są w stanie zapewnić klasyczne algorytmy oparte na regułach.

W tej pracy, do sprawdzenia działania opracowanego algorytmu harmonogramowania wykorzystano magazyn energii elektrycznej. Jest to jeden z przykładów możliwości zastosowania tego algorytmu, ponieważ otrzymane wyniki badań jednoznacznie wskazują, że jest to narzędzie uniwersalne, które może zostać wykorzystane do pracy z dowolnym magazynem energii.

ABSTRACT

The objective of this doctoral dissertation was to develop and validate a proprietary control algorithm for energy storage integrated with renewable energy sources, forming a Hybrid Energy System (HES). The task of the developed algorithm, based on the proposed objective function, was to optimize the utilization of energy stored in the storage system for self-consumption or for exchange with the power grid, in order to achieve the highest electricity sales price. Both meteorological data and information on energy price volatility were used as input data.

For the optimization of the energy storage operation, a hybrid approach was proposed utilizing Long Short-Term Memory (LSTM) artificial neural networks and a Genetic Algorithm (GA) with a modified population initialization procedure. As initial conditions, the Genetic Algorithm uses the results obtained from a deterministic Rule-Based (RB) algorithm solution. The results demonstrate that this approach allows for the faster development of an optimal energy storage operation schedule within a Day-Ahead time horizon by eliminating the risk associated with the initial randomness of solutions.

To achieve the aim of the study, a mathematical model of a hybrid energy system composed of a photovoltaic installation, a wind turbine, an energy storage system, and a local load was developed. In the first stage, the effectiveness of the developed algorithm (GA) was compared with classic Rule-Based (RB) control. Real-world meteorological data and price dynamics with a 15-minute resolution for one full calendar year were used to conduct the simulations. Analysis of the obtained results showed that the application of the proposed genetic algorithm allows for achieving greater economic benefits compared to the RB method, even after accounting for storage degradation costs. Distinct benefits resulting from the increase in the number of storage charging and discharging cycles, caused by intelligent price arbitrage, were also demonstrated. This strategy is economically justified and significantly outperforms strategies based solely on maximizing self-consumption. The conducted sensitivity analysis showed that, in addition to meteorological data and energy price dynamics, the storage capacity and its State of Charge (SoC) at the end of the day are also key parameters that should be taken into account.

In the subsequent stage, a validation of the proposed control algorithm's operation was conducted using data collected from a real-world facility. In this case as well, the obtained results clearly indicate that the proposed proprietary scheduling algorithm leads to a significant increase in economic profits thanks to the possibility of implementing dynamic price arbitrage, which classic rule-based algorithms are unable to provide.

In this thesis, an electrical energy storage system was used to verify the operation of the developed scheduling algorithm. This serves as one example of the algorithm's potential applications, as the obtained research results unequivocally indicate that it is a universal tool that can be utilized to operate with any type of energy storage system.

SPIS TREŚCI

1.	WPROWADZENIE	10
2.	PRZEGLĄD LITERATURY	15
2.1.	Hybrydowe systemy zasilania	15
2.2.	Algorytmy zarządzania energią	17
	Metody oparte na regułach	18
	Metody deterministyczne	21
	Metody sztucznej inteligencji	22
2.3.	Wnioski wynikające z przeglądu literatury	24
3.	CEL, ZAKRES I TEZA PRACY	27
3.1.	Cel pracy	27
3.2.	Zakres pracy	27
3.3.	Teza pracy	27
4.	AUTORSKI ALGORYTM HARMONOGRAMOWANIA PRACY MAGAZYNU ENERGII ZINTEGROWANY Z HYBRYDOWYM SYSTEMEM ZASILANIA	28
4.1.	Algorytm harmonogramowania	28
4.2.	Implementacja algorytmu harmonogramowania	35
5.	HYBRYDOWY SYSTEM ZASILANIA TYPU SŁONECZNO-WIATROWEGO Z MAGAZYNEM ENERGII	43
5.1.	Model systemu fotowoltaicznego	43
	Model matematyczny komponentów PV	43
	Implementacja modelu PV w MATLAB/Simulink	46
5.2.	System wiatrowy	49
	Model matematyczny turbiny wiatrowej TW o osi poziomej	49
	Implementacja modelu turbiny wiatrowej TW w MATLAB/Simulink	51
5.3.	System magazynowania energii	53
5.4.	Model obciążenia lokalnego	55
5.5.	Bilans mocy i współpraca z siecią elektroenergetyczną	55
6.	SYMULACJA PRACY MODELU HYBRYDOWEGO SYSTEMU ZASILANIA TYPU SŁONECZNO-WIATROWEGO Z MAGAZYNEM ENERGII	57
6.1.	Założenia do symulacji	57
6.2.	Hybrydowy System Zasilania z algorytmem regułowym (RB) – wyniki symulacji i ich analiza	61
	Efektywność ekonomiczna	62
	Analiza wrażliwości	64
6.3.	Hybrydowy System Zasilania z algorytmem genetycznym (GA) – wyniki symulacji komputerowej	65

Efektywność ekonomiczna	66
Analiza mechanizmu działania	68
Analiza wrażliwości na pojemność i SoC na koniec dnia	70
7. SYMULACJA PRACY HYBRYDOWEGO SYSTEMU ZASILANIA TYPU SŁONECZNO- WIATROWEGO Z MAGAZYNEM ENERGII Z WYKORZYSTANIEM RZECZYWISTYCH DANYCH POMIAROWYCH.....	74
7.1. Hybrydowy system zasilania	74
7.2. Założenia do symulacji.....	76
7.3. Prognozowanie generacji ze źródeł OZE	79
7.4. Scenariusze sterowania i optymalizacji	88
HSZ bez magazynowania – scenariusz 1	88
HSZ z magazynem energii i algorytmem bilansowania (RB)– scenariusz 2.....	89
HSZ z magazynem energii i autorskim algorytmem optymalizacji (GA)– scenariusz 3...93	
7.5. Analiza porównawcza i dyskusja wyników.....	99
7.6. Analiza stabilności czasowej	101
8. PODSUMOWANIE I WNIOSKI	103
LITERATURA.....	105

Tabela 1. Skróty anglojęzyczne

Skrót	Rozwinięcie	Znaczenie
<i>ANN</i>	Artificial Neural Network	Sztuczna Sieć Neuronowa
<i>BESS</i>	Battery Energy Storage System	Bateryjny system magazynowania energii
<i>DP</i>	Dynamic Programming	Programowanie dynamiczne
<i>DRL</i>	Deep Reinforcement Learning	Głębokie uczenie ze wzmocnieniem
<i>DSM</i>	Demand Side Management	Zarządzanie stroną popytu (sterowanie obciążeniem)
<i>DWD</i>	Deutscher Wetterdienst	Niemiecki serwis meteorologiczny (źródło danych)
<i>GA</i>	Genetic Algorithm	Algorytm genetyczny
<i>GWO</i>	Grey Wolf Optimizer	Algorytm szarego wilka
<i>EMS/ HEMS</i>	Energy Management System/ Hybrid Energy Management System	System zarządzania energią/ Hybrydowy System zarządzania energią
<i>HES</i>	Hybrid Energy System	Hybrydowy System Zasilania
<i>ISFLA</i>	Improved Shuffled Frog Leaping Algorithm	Ulepszony algorytm tasowania żab
<i>LP</i>	Linear Programming	Programowanie liniowe
<i>LSTM</i>	Long Short-Term Memory	Długa pamięć krótkotrwała (typ sieci neuronowej)
<i>MAE</i>	Mean Absolute Error	Średni błąd bezwzględny
<i>MILP</i>	Mixed Integer Linear Programming	Mieszane programowanie liniowe całkowitoliczbowe
<i>MPPT</i>	Maximum Power Point Tracking	Śledzenie maksymalnego punktu mocy (PV i wiatrowe)
<i>OPEX</i>	Operating Expenditures	Koszty operacyjne (utrzymanie systemu)
<i>P&O</i>	Perturb & Observe	Metoda zaburzeń i obserwacji (algorytm MPPT)
<i>PHEV</i>	Plug-in Hybrid Electric Vehicles	Hybrydowe pojazdy elektryczne typu plug-in
<i>PMSG</i>	Permanent Magnet Synchronous Generator	Generator synchroniczny z magnesami trwałymi
<i>PSO</i>	Particle Swarm Optimization	Optymalizacja rojem cząstek
<i>PV</i>	Photovoltaic	Fotowoltaika / Systemy fotowoltaiczne
<i>RB</i>	Rule-Based	Algorytm/sterowanie oparte na regułach
<i>RMSE</i>	Root Mean Square Error	Błąd średniokwadratowy
<i>SEI</i>	Solid Electrolyte Interphase	Warstwa pasywna na elektrodzie
<i>SMA</i>	Slime Mould Algorithm	Algorytm śluzowca
<i>SOC</i>	State of Charge	Stan naładowania magazynu energii
<i>SSA</i>	Simulated Annealing	Symulowane wyżarzanie
<i>STC</i>	Standard Test Conditions	Standardowe warunki testowania (paneli PV)

<i>VPP</i>	Virtual Power Plant	Wirtualna elektrownia
<i>VRFB</i>	Vanadium Redox Flow Batteries	Wanadowe baterie przepływowe
<i>WT</i>	Wind Turbine	Turbina wiatrowa


Tabela 2. Skróty polskie

Skrót	Rozwinięcie	Znaczenie
HSZ	Hybrydowy System Zasilania	Polski odpowiednik skrótu HES
OZE	Odnawialne Źródła Energii	Np. energia z słońca i wiatru
PSE	Polskie Sieci Elektroenergetyczne	Operator systemu przesyłowego w Polsce
RCE	Rynkowa Cena Energii	Wskaźnik cenowy na rynku energii (godzinowy/15-min)
RCEm	Rynkowa miesięczna Cena Energii	Średnia miesięczna cena
SSN	Sztuczna Sieć Neuronowa	Polski odpowiednik ANN
TW	Turbina Wiatrowa	Polski odpowiednik skrótu WT

1. WPROWADZENIE

Aktualnie dużym wyzwaniem jest globalne rosnące zapotrzebowanie na energię elektryczną, które wymaga rozbudowy lub wprowadzania nowych mocy wytwórczych do systemów elektroenergetycznych. Niezmiennie w większości krajów na świecie udział konwencjonalnych źródeł energii w krajowym miksie energetycznym jest dominujący, a jak wiadomo źródła te ulegają stopniowemu wyczerpaniu. Szacuje się, że zapasy paliw kopalnych wystarczą na: 45 lat - ropa naftowa, 200 lat - węgiel oraz 60 lat - gaz ziemny [51]. Ograniczone zasoby tych paliw oraz wpływ ich spalania na środowisko spowodowało zanieczyszczanie powietrza przez emisję gazów cieplarnianych. Obecnie szacuje się, że ponad 30% globalnej emisji gazów cieplarnianych stanowi emisja pochodząca z sektora energetycznego, co wskazuje na istotny, negatywny wpływ tego sektora na środowisko [42]. Wiele krajów, szczególnie krajów Unii Europejskiej, mając na uwadze postępujący proces globalnego ocieplenia podjęło decyzję o stopniowym ograniczaniu emisji tych gazów. Skutki te przyczyniły się do modernizacji krajowych struktur energetycznych oraz poszukiwania innych, alternatywnych źródeł energii, m.in. źródeł odnawialnych. Zgodnie z Dyrektywą z 2018 roku dotyczącą odnawialnych źródeł energii, kraje członkowskie UE zobowiązały się do stopniowego zwiększania udziału Odnawialnych Źródeł Energii w różnych sektorach gospodarki, kładąc największy nacisk na sektor przemysłowy. Założono się, że udział energii odnawialnej w końcowym jej zużyciu brutto w UE osiągnie co najmniej 32% w roku 2030. Takie działania spowodowały, że odnawialne źródła energii z każdym rokiem odgrywają coraz większą rolę w całkowitym bilansie wytwarzania energii w UE. Stąd w Unii Europejskiej, w tym w Polsce, od kilkunastu już lat zauważalne jest rosnące zainteresowanie technologiami odnawialnymi, zwłaszcza instalacjami fotowoltaicznymi i farmami wiatrowymi. Świadczy o tym wzrost liczby prosumentów i firm zainteresowanych technologiami OZE, zwłaszcza tych w sektorach wysoko energochłonnych, w których zakup energii stanowi główny koszt funkcjonowania przedsiębiorstwa [46].


Obecnie do najpopularniejszych źródeł wytwórczych energii odnawialnej można zaliczyć panele fotowoltaiczne oraz wiatraki, w których energia elektryczna wytwarzana jest z odpowiednio z energii promieniowania słonecznego i z energii mechanicznej wiatru. W krajowym miksie energetycznym na koniec 2024 roku udział odnawialnych źródeł energii w ogólnym wytwarzaniu energii w Polsce wyniósł ponad 49%, a zainstalowana moc OZE przekroczyła 32 GW, w tym około 60 % energii odnawialnej stanowiła energia słoneczna, a około 30 % to energia wiatru (Rys. 1.1.) [28].



Rys.1.1. Udział źródeł OZE w wytwarzaniu energii odnawialnej, opracowanie własne wg[28]]

Niestety, zarówno energia słoneczna, jak i z wiatru charakteryzują się dużą zmiennością w czasie, wywołane jest to zmiennymi warunkami meteorologicznymi - (zachmurzeniem), porą roku, zanieczyszczeniem powietrza, a w przypadku wiatru mogą to być: zmienna prędkość, sezonowość czy ukształtowanie terenu. Zmiany te zazwyczaj mają charakter cykliczny, ale mogą być również bardzo dynamiczne (np. nagłe zmiany warunków meteorologicznych nawet w ciągu jednej godziny) [10]. W związku z tym, jednym z najważniejszych wyzwań związanych z rozwojem technologii OZE i ich wykorzystaniem, jest niwelowanie skutków zależności wytwarzania energii elektrycznej od trudnych do przewidzenia zmian warunków pogodowych.

Kolejnym ważnym aspektem mającym duży wpływ na szybkość rozwoju sektora odnawialnych źródeł energii w Polsce, jak i w Unii Europejskiej jest rosnąca cena energii elektrycznej (Rys. 1.2).



Rys. 1.2. Ceny energii elektrycznej dla gospodarstw domowych na przestrzeni ostatnich lat w Unii Europejskiej, opracowanie własne na podstawie [19]

Z uwagi na ciągły jej wzrost, a w konsekwencji znaczący wzrost rachunków za energię elektryczną, inwestycja w OZE staje się coraz bardziej opłacalna. Jak wynika z Rys. 1.2. tylko od 2019 roku do końca 2023 roku cena energii elektrycznej wzrosła o ponad 60 % na rynku krajowym i średnio o około 30 % dla wszystkich krajów Unii Europejskiej [19]. Stąd też, rosnące rachunki za energię elektryczną wymuszają na odbiorcach końcowych, w tym gospodarstwach domowych oraz przedsiębiorstwach, a poszukiwanie metod obniżania kosztów zużycia energii.

Mając na uwadze zmienność wytwarzania energii z OZE w czasie oraz bardzo szybko rosnące ceny, konieczne jest integrowanie tych technologii z technologiami magazynowania energii elektrycznej. Dzięki temu możliwe jest kontynuowanie globalnie rosnącego trendu wytwarzania energii elektrycznej z OZE, przy jednoczesnym zapewnieniu niskich cen energii oraz stabilności systemu energetycznego [53]. Niewątpliwą zaletą takiego połączenia jest to, że taki system wymaga mniejszej mocy przyłączeniowej, w celu zaspokojenia średniego zapotrzebowania na energię przy jednoczesnym niwelowaniu chwilowego zapotrzebowania szczytowego. Zabezpiecza to przed dodatkowymi opłatami za pobór energii z sieci elektrycznej [35]. Stąd, aby dobrze wykorzystać możliwości integracji technologii wytwarzania energii z OZE z technologiami magazynowania, konieczne staje się zastosowanie systemu zarządzania pracą magazynu energii. Jest to bardzo istotne, ponieważ to systemy zarządzania energią, decydują o rentowności działania układu. Dodatkowo wykorzystanie inteligentnego systemu zarządzania może przyczynić się do zwiększenia stabilności i elastyczności systemu elektroenergetycznego, zarówno na poziomie krajowym, jak i w sieci lokalnej. Implementacja

zaawansowanych algorytmów sterowania magazynem może znacząco obniżyć końcowe koszty energii elektrycznej dla lokalnych odbiorów, czy odbiorców przemysłowych.

Aktualnie trwająca transformacja sektora energetycznego w Polsce wpływa na zmianę podejścia z modelu centralnego sterowania do modelu opartego na elastycznym popycie oraz generacji rozproszonej. Jest to spowodowane bezpośrednią implementacją dyrektywy UE 2019/944 [16] w Polskim prawodawstwie - Ustawa z dnia 20 lutego 2015 r. o odnawialnych źródłach energii (Art. 1) [66]. Wprowadzenie tych regulacji wymusza fundamentalne zmiany w mechanizmach rozliczeń prosumentów oraz zasadach eksploatacji magazynów energii.

Pierwotnym mechanizmem rozliczeń w sektorze a energetyki prosumenckiej w Polsce był model net-meteringu, który obowiązywał do 31 marca 2022 r. (Ustawa o OZE, Art. 4 ust. i Art. 4d) [66]. Jest to model polegający na rozliczeniu o charakterze ilościowym, w którym sieć elektroenergetyczna pełni rolę tzw. „wirtualnego magazynu energii” o stałej sprawności określonej ustawowo. W modelu tym, bilans energii obliczany jest jako różnica między energią pobraną, a oddaną do sieci w danym okresie rozliczeniowym. Nadwyżka energii, pomniejszona o współczynnik opustu, może zostać odebrana przez prosumenta w okresie 365 dni. Zasadniczą cechą net-meteringu jest brak narażania prosumenta na ceny rynkowe, a sieć jest traktowana jako nieskończony magazyn energii elektrycznej o stałej sprawności. W efekcie nie zachęca to do wzrostu zużycia na potrzeby własne w szczytowych okresach generacji i nie wspomaga bilansowania systemu.

Kluczowym elementem reformy Rynku Energii jest odejście od modelu ilościowego (net-metering) na rzecz modelu wartościowego (net-billing) w rozliczeniach dla prosumentów. Zmiany te zostały wprowadzone w reakcji na przeciążenie sieci niskiego napięcia, poprzez skokowy wzrost liczby nowych instalacji fotowoltaicznych na przestrzeni kilku ostatnich lat. Wprowadzenie net-billingu ma na celu to, aby prosument był motywowany do oddawania energii do sieci, gdy jest ona droga i zwiększaniu zużycia lub jej magazynowaniu, gdy cena jest niska lub ujemna. W konsekwencji, model net-billingu wymusza konieczność inwestycji w magazyny energii oraz inteligentne systemy zarządzania. Wpływa to na ograniczenie do minimum ilości energii oddawanej bezpłatnie lub po bardzo niskich cenach do sieci. W systemie net-billingu, wartość energii wyeksportowanej do sieci oraz importowanej została rozdzielona, a cena sprzedaży energii elektrycznej do sieci została określana dynamicznie za pomocą tzw. Rynkowej Ceny Energii (RCE), która jest wyznaczana przez Operatora Systemu Przesyłowego (PSE).

W okresie przejściowym wdrażania modelu net-billingu, który obowiązywał do dnia 30 czerwca 2024 r., podstawą do rozliczeń sprzedanej energii elektrycznej jest rynkowa

miesięczna cena energii elektrycznej (RCEm) - (Ustawa o OZE, Art. 4b) [66]. RCEm jest obliczana ex-post przez PSE, jako średnia ważona z rynkowych cen energii elektrycznej (RCE) dla danego miesiąca. Mechanizm ten sztucznie podnosił wartość importu energii z fotowoltaiki, ponieważ sprzedaż energii wprowadzanej w godzinach szczytu południowego (niskie lub ujemne ceny energii) były rozliczane po średniej cenie z całego miesiąca, która mogła być niejako zwiększana przez wysokie ceny energii w szczytach wieczornych (najwyższe ceny energii).

Od 1 lipca 2024 r. obowiązującym mechanizmem rozliczeń dla nowych prosumentów jest wskaźnik Rynkowa Cena Energii - RCE (Ustawa o OZE, Art. 4b) [66]. Cena sprzedaży wyznaczana jest dla każdej godziny i każdego dnia, na podstawie notowań giełdowych publikowanych dzień wcześniej. W tym mechanizmie, wartość depozytu prosumenta staje się mocno skorelowana z profilem wytwarzania energii. W konsekwencji wymusza to na prosumentach optymalizację pracy instalacji w cyklu dobowym, a nie miesięcznym, aby uniknąć importu energii do sieci w okresach nadpodaży, czyli wtedy, kiedy cena energii jest niska. Nowelizacja ustawy o OZE z 27 grudnia 2024 r. wprowadziła przelicznik 1,23 do wartości energii oddawanej przez prosumentów do sieci co realnie zwiększa depozyt prosumencki o 23% (Ustawa o OZE, Art. 4c) [66].

Dodatkowo od 30 września 2025 roku system net-billingu przeszedł ostateczną transformację z rozliczeń godzinowych na rozliczenia 15-minutowe. Od tej daty RCE zmienia się co 15-minut, co wymaga większej precyzji w sterowaniu zasobami OZE współpracującymi z magazynami energii [59].

2. PRZEGLĄD LITERATURY


Każdego roku rośnie wartość zainstalowanej mocy, zarówno systemów fotowoltaicznych, jak i wiatrowych, w globalnym miksie energetycznym. W celu wzrostu niezawodności tych systemów coraz częściej integruje się je we wspólne systemy, które podłączane są do sieci energetycznej. Jak już wspomniano, ich zasadniczą wadą jest zmienność generacji energii elektrycznej w czasie, która zależy od warunków pogodowych, pory dnia czy roku. Również charakterystyka wytwarzania energii elektrycznej systemu solarno-wiatrowego może nie pokrywać się z charakterystyką zapotrzebowania na energię przez urządzenia odbiorcze. Do tego, biorąc pod uwagę dynamikę cen energii elektrycznej, rośnie zapotrzebowanie na systemy zarządzania energią. Ich celem jest minimalizacja kosztów zużycia energii elektrycznej, dzięki temu decydują o opłacalności wdrożenia i późniejszej eksploatacji hybrydowych systemów zasilania.

2.1. Hybrydowe systemy zasilania

Modelowanie hybrydowych systemów zasilania, złożonych z odnawialnych źródeł energii i konwencjonalnych źródeł energii stanowi ważny element obszaru badawczego w dziedzinie energetyki i elektroenergetyki. Systemy te oferują dla użytkownika dużą elastyczność i niezawodność, a dodatkowa integracja magazynów energii zapewnia efektywne wykorzystanie źródeł OZE, przy jednoczesnym zapewnieniu stabilności dostaw energii elektrycznej.


Hybrydowe systemy zasilania ze względu na architekturę sieci zasadniczo można podzielić na dwa typy [2]:

- hybrydowe systemy zasilania z siecią prądu stałego,
- hybrydowe systemy zasilania z siecią prądu przemiennego.



Rys.2.1. Przykładowy schemat hybrydowego systemu zasilania, złożonego z OZE oraz magazynu energii sprzężonych we wspólną magistralę prądu stałego, podłączonego do sieci elektroenergetycznej[21]

Hybrydowe systemy zasilania z siecią prądu stałego składają się z różnych źródeł sprzężonych w jedną wspólną magistralę prądu stałego. Przykładowy schemat takiego systemu pokazano na Rys. 2.1. [21]. Przedstawiony na Rys. 2.1. hybrydowy system zasilania składa się z systemu: fotowoltaicznego, turbiny wiatrowej oraz baterijnego magazynu energii. Wymienione systemy pracują na wspólnej magistrali prądu stałego, z którą są połączone za pomocą konwerterów DC/DC - w przypadku paneli fotowoltaicznych i magazynu energii oraz za pomocą konwertera AC/DC - w przypadku turbiny wiatrowej. Transfer z oraz do hybrydowego systemu zasilania energii elektrycznej zapewnia dwukierunkowy konwerter AC/DC, który łączy wspólną magistralę prądu stałego z siecią zasilającą. Zastosowanie konwertera DC/DC w systemie fotowoltaicznym i konwertera AC/DC w systemie turbiny wiatrowej umożliwia zaimplementowanie algorytmu MPPT (ang. Maximal Point Power Tracking), czyli algorytmu śledzenia maksymalnego punktu pracy dla każdego z systemów. Pozwala to na maksymalizację wytwarzania energii elektrycznej w tych źródłach[2].



Rys.2.2. Przykładowy schemat hybrydowego systemu zasilania, złożonego z OZE oraz magazynu energii sprzężonych we wspólną magistralę prądu przemiennego, podłączonego do sieci elektroenergetycznej[21]

Z kolei hybrydowe systemy zasilania sprzężone z siecią prądu przemiennego składają się z różnych źródeł i połączone są w jedną wspólną magistralę prądu przemiennego [21]. Przykładowy schemat takiego systemu pokazano na Rys. 2.2. Zasadniczą różnicą tego typu architektury jest to, że każde źródło energii posiada dedykowany przetwornik DC/AC, zamiast jednego wspólnego przetwornika. Takie rozwiązanie wymusza stosowanie oddzielnych przetworników dla każdego ze źródeł energii, co z jednej strony wiąże się z większymi kosztami inwestycji, ale z drugiej strony zwiększa niezawodność systemu. Dla systemu fotowoltaicznego i systemu turbiny wiatrowej również stosuje się algorytm śledzenia maksymalnego punktu pracy [2].

2.2. Algorytmy zarządzania energią

Bardzo ważnym obszarem zainteresowań naukowych związanym z Hybrydowymi Systemami Zasilania (HSZ) są Systemy Zarządzania Energią (EMS). Przeprowadzony przegląd literatury naukowej wskazuje na dużą różnorodność badań prowadzonych w tym obszarze i wskazuje na bardzo duże zainteresowanie tematem optymalizacji sterowania magazynem energii. Popularnym zagadnieniem jest również optymalizacja doboru wielkości komponentów systemów hybrydowych [54][57], chociaż niniejsza rozprawa porusza temat optymalizacji sterowania magazynu energii, te dwa zagadnienia mają niejako na siebie wpływ.

Przyjęta wielkość magazynu determinuje rzeczywistą przestrzeń decyzyjną, zależną od jego mocy i pojemności, dla algorytmu sterowania. W niektórych publikacjach poruszane są oba te zagadnienia w sposób integralny [7][50][70] .

Z pewnością kwestie ekonomiczne są jedną z najważniejszych przyczyn popularyzacji systemów zarządzania energią. Magazyny energii zintegrowane w HSZ zwiększają elastyczność mikrosieci poprzez wprowadzenie możliwości przesunięcia krzywej zużycia energii wtedy, kiedy jest ona najtańsza lub przesunięcia krzywej generacji, gdy energia jest najdroższa w celu jej późniejszej sprzedaży [9]. Mechanizmy te umożliwiają wzrost zużycia energii na potrzeby własne w przypadku pojawienia się nadwyżek energii z OZE przy jednoczesnym ograniczeniu poboru energii z sieci, co dzieje się w okresach wysokich cen energii. Inne podejście prezentowane jest w publikacjach, gdzie proponowane jest zagospodarowanie „odnawialnej energii traconej”, czyli takiej, której sieć nie może przyjąć, za pomocą hybrydowych magazynów energii [32] lub połączenie hybrydowych magazynów energii i układu wodorowego [31]. Takie podejście wskazuje na trend poszukiwania metod magazynowania o różnej dynamice i pojemności, co komplikuje funkcje celu i jej ograniczenia.

Kompleksowy przegląd systemów zarządzania energią przedstawiono w artykułach [17][33] [64][73] klasyfikując je ze względu na architekturę i cele sterowania lub sposób optymalizacji. Systemy zarządzania energią pełnią kluczową rolę w określaniu opłacalności wdrażania systemów magazynowania energii i mogą być stosowane w różnych środowiskach, w zależności od potrzeb użytkownika: mieszkalnym [44][62], biurowym [39] i rozproszonym - tzw. wirtualna elektrownia [22][48][55].

Metody oparte na regułach

W systemach zarządzania energią nadal z powodzeniem stosuje się algorytmy o niskiej złożoności obliczeniowej, takie jak metody oparte na regułach (RB) [69]. Ich główną zaletą jest niski koszt wdrożenia. W pracy [8] opisano przykład wdrożenia prostego sterowania regułowego w systemie z wodorowym magazynem energii zintegrowanym z panelami fotowoltaicznymi. Autorzy wykazali, że zastosowanie prostego sterowania pozwala jednocześnie na redukcję kosztów implementacji układu sterowania i efektywną pracę systemu wodorowego, zapewniając stabilność zasilania.

Podobny system zarządzania pokazano w pracy [72], rozważane systemy zasilania zostały dodatkowo wyposażone w baterijny magazyn litowo-jonowy. Zastosowanie baterii litowo-jonowej, o odpowiedniej pojemności, może tłumić wahania mocy, gromadzić nadmiar

energii z OZE i oddawać ją w momentach deficytu, w celu zasilenia lokalnego obciążenia. Przytoczony w pracy przykład pracował wyspowo, bez połączenia z siecią dystrybucyjną.

Z kolei wodorowy systemem magazynowania zaproponowano w pracy [11] w hybrydowym słoneczno-wiatrowym systemie zasilania, który również pracował wyspowo. Autorzy zweryfikowali działanie proponowanego algorytmu na rzeczywistym stanowisku badawczym. Stwierdzono, że zaproponowany system sterowania zapewnia niezawodną pracę mikrosieci.

Te same zagadnienie poruszono w publikacji [20], gdzie wykazano, że pełna autonomia mikrosieci w oparciu o OZE jest technicznie wykonalna. Autorzy stwierdzają, że w takich konfiguracjach najważniejszym czynnikiem jest konieczność dużego przewymiarowania pojemności magazynu energii i wartości mocy zainstalowanej w źródłach OZE. Wiąże się to jednak z bardzo wysokimi kosztami inwestycyjnymi. Stwierdzono również, że systemy autonomiczne mogą mieć znaczący potencjał, ale głównie w obszarze elektryfikacji miejsc bez istniejącej struktury elektroenergetycznej. Takie wnioski potwierdzono także w publikacjach [49][65]. Autorzy wykazali, że HSZ podłączone do sieci elektroenergetycznej są bardziej opłacalne niż konfiguracje wyspowe. Stwierdzono, że stosowanie baterijnego magazynu energii o dużej pojemności wyłącznie do pracy wyspowej jest nieuzasadnione ekonomicznie. W autonomicznych HSZ konieczność zapewnienia ciągłości zasilania wyłącznie w oparciu o źródło lokalne znacząco podnosi koszt energii elektrycznej. Chociaż wnioski z prac [49][65] są nadal aktualne, to należy mieć na uwadze dynamiczny spadek cen technologii magazynowania baterijnego oraz OZE, co znacząco poprawia wskaźniki ekonomiczne systemów typu wyspowego, korzystających z tych technologii.

W pracy [14] zaprezentowano system zarządzania energią stacji ładowania pojazdów, wyposażoną w system solarno-wiatrowy oraz baterijny magazyn energii. Autorzy zaimplementowali strategię sterowania regułowego RB. Celem sterowania była minimalizacja poboru energii z sieci z jednoczesną maksymalizacją jej wykorzystania na potrzeby własne. Nowością w pracy, było połączenie prostej logiki sterowania z metodami predykcji. Do predykcji wytwarzania energii z OZE zastosowano sztuczne sieci neuronowe, do przewidywania kształtu charakterystyki obciążenia natomiast zastosowano symulacje Monte Carlo. Uzyskana skuteczność prognoz generacji energii z fotowoltaiki wyniosła dla RMSE 15,6%, a dla MAE 11,3% maksymalnej wartości prognozowanej.

Inne podejście zaproponowano w [38], gdzie strategię regułową oparto na stanie naładowania SOC (ang. State of Charge) magazynów energii. Analizowana mikrosieć składała się z instalacji fotowoltaicznej oraz hybrydowego magazynu energii - baterii elektrochemicznej

i superkondensatorów. Zadaniem superkondensatorów było reagowanie na szybkozmienne wahania mocy. Dzięki zastosowaniu algorytmu regułowego wykorzystującego stan naładowania magazynów o 15% zmniejszeniu uległa liczba cykli pracy baterii, co wydłużyło trwałość systemu.

W publikacji [26] autorzy zaproponowali zdecentralizowane sterowanie regułowe, które jest odporne na zmiany konfiguracji w mikrosieci (np. rozbudowa systemu PV). Na podstawie analizy badań wynika, że sterowanie regułowe jest skuteczną i skalowalną metodą bilansowania, przez co jest atrakcyjną alternatywą dla złożonych metod optymalizacyjnych.

W pracy [63] autorzy zaproponowali algorytm hybrydowy, w którym algorytm regułowy (drzewo decyzyjne) działa w czasie rzeczywistym z krokiem 1 min i koryguje harmonogram działania magazynów wyznaczony przez algorytm optymalizacyjny, wykorzystujący mieszane programowanie liniowe całkowitoliczbowe MILP. Proste algorytmy regułowe doskonale sprawdzają się jako uzupełnienie dla zaawansowanych metod optymalizacji.

Niestety, proste strategie sterowania systemami zarządzania energią mogą prowadzić do nieoptymalnych decyzji. Takie sterowanie może znacząco zwiększyć koszty operacyjne i przyspieszyć degradację elementów systemu magazynowania (np. zwiększona liczba cykli). W następstwie tego, w celu osiągnięcia znaczących korzyści ekonomicznych, wynikających z integracji systemów magazynowania, w pełni zasadne wydaje się implementowanie zaawansowanych systemów zarządzania energią dla HSZ. Systemy hybrydowe z reguły charakteryzują się dużą złożonością - integrują dwa lub więcej źródeł energii, zazwyczaj niestabilnych, zależnych od pogody, a jednocześnie mogą integrować taryfy strefowe lub dynamikę cen energii. W związku z tym, przewaga zaawansowanych algorytmów optymalizacji nad prostymi metodami sterowania polega na inteligentnym sterowaniu przepływami mocy w systemie, w taki sposób, aby zminimalizować koszty wytwarzania energii elektrycznej poprzez dostosowanie pracy systemu do zmiennych warunków zewnętrznych takich jak pogoda, lokalne zużycie energii, czy jej zmienne ceny. Zaawansowane systemy optymalizacji umożliwiają maksymalizację zysków ze sprzedaży lub maksymalizację użycia dostępnych zasobów energii, najczęściej odnawialnej, poprzez harmonogramowanie pracy magazynu energii, co ma wpływ na jego rentowność.

Metody deterministyczne

Metody optymalizacji ze względu na sposób poszukiwania rozwiązania można podzielić na metody stochastyczne i deterministyczne. Wybór odpowiedniej metody optymalizacji powinien zależeć od analizowanego problemu. Każda z metod ma swoje zalety oraz wady. Metody deterministyczne to takie, które działają w sposób przewidywalny i powtarzalny, a ich działanie polega na analizie funkcji celu i jej pochodnych. Takie same dane wejściowe zawsze prowadzą do tych samych wyników. Natomiast metody stochastyczne są metodami, które wykorzystują losowość i statystykę, a wynik optymalizacji dla tych samych danych wejściowych za każdym razem może być inny.

W kontrze do metod sterowania regułowego, które opierają się na warunkach logicznych, metody deterministyczne polegają na matematycznej optymalizacji wybranej funkcji celu. Najczęściej zdefiniowana funkcja celu jest optymalizowana pod kątem minimalizacji kosztów operacyjnych lub maksymalizacji wykorzystania energii z OZE, przy zachowaniu ograniczeń technicznych, wynikających z parametrów znamionowych urządzeń magazynujących lub przyłącza sieci elektroenergetycznej.

Dużą popularnością cieszy się metody Programowania Liniowego (LP) [13][52], Mieszane Całkowitoliczbowe Programowanie Liniowe (MILP) [37][63] i Programowanie Dynamiczne (DP) [34]. Przykładowo, w pracy [13] zaprezentowano model optymalizacji harmonogramu pracy systemu BESS zintegrowanego ze źródłami rozproszonymi, wykorzystujący LP do maksymalizacji zysków z arbitrażu oraz redukcji szczytów obciążenia. Autorzy uwzględnili ograniczenia systemu magazynowania, takie jak dopuszczalna głębokość rozładowania czy limity prądowe. Należy jednak zauważyć, że podejście to wymaga linearyzacji funkcji celu i ograniczeń, co może prowadzić do utraty dokładności w odwzorowaniu nieliniowych procesów, takich jak degradacja ogniw elektrochemicznych, co stanowi ograniczenie np. względem metod algorytmów genetycznych.

W publikacji [34] do rozwiązania problemu minimalizacji kosztów operacyjnych mikrosieci wykorzystano programowanie dynamiczne. Wykazano, że w mikrosieciach złożonych z OZE i energetyki konwencjonalnej, optymalizacja pracy magazynu energii pozwala na znaczącą redukcję kosztów operacyjnych. Algorytm uwzględnia zmienną dynamikę cen energii oraz szereg ograniczeń technicznych magazynu, takich jak stan naładowania (SOC) oraz limity mocy ładowania/rozładowania. Podejście to pozwala na minimalizację całkowitego kosztu zakupu energii poprzez inteligentne zarządzanie energią zmagazynowaną w okresach niskich cen i jej wykorzystanie w szczytach cenowych. Skuteczność metody potwierdzono na

podstawie rzeczywistych danych pomiarowych i cenowych z sześciu różnych lokalizacji, wykazując wymierne oszczędności przy różnych pojemnościach systemów BESS.

W pracy [36] skupiono się na możliwości optymalizacji za pomocą programowania liniowego, które zaimplementowano w środowisku Matlab. Badano system magazynowania energii w wodzie, wykorzystując wody gruntowe, a jako funkcje celu autorzy określili minimalizację kosztów energii pobieranej z sieci przy jednoczesnej maksymalizacji energii oddawanej do sieci. Symulacje wykazały, że zastosowanie optymalnego sposobu sterowania pozwala na oszczędności rzędu 68,44% w porównaniu do zasilania wyłącznie z sieci.

W publikacji [4] autorzy zaproponowali zastosowanie techniki programowania dynamicznego DP do optymalizacji harmonogramowania akumulatorowego magazynu energii z uwzględnieniem kosztów degradacji. Autorzy przeprowadzili analizę wrażliwości i skupili się na dwóch parametrach, które determinują opłacalność inwestycji: stan naładowania (SOC) na koniec dnia oraz pojemność magazynu. Innym wyzwaniem dla metod deterministycznych pozostają nieliniowe charakterystyki urządzeń, takich jak magazyny szczytowo-pompowe [25] czy hybrydowe systemu magazynowania [53].

W artykule [53] opisano metodę sterowania dwoma zasobnikami energii - bateriami przepływowymi wanadowymi (VRFB) oraz bateriami litowo-jonowymi. Celem sterowania była minimalizacja kosztów wytwarzania energii elektrycznej wykorzystując autorski, deterministyczny algorytm optymalizacyjny. W badanej konfiguracji zadaniem baterii przepływowej było dobowe bilansowanie energii, natomiast baterii Li-ion kompensacja szybkich wahań mocy. W pracy opracowano i zweryfikowano model techniczno-ekonomiczny uwzględniający degradację akumulatorów. Autorzy wykazali, że system sterowania wraz z magazynami energii zwiększa wykorzystanie energii na potrzeby własne i skutecznie obniża koszty energii elektrycznej z jednoczesnym wzrostem kosztów amortyzacji baterii.

Metody sztucznej inteligencji

Dużą popularnością cieszą się również systemy zarządzania energią, które wykorzystują metody sztucznej inteligencji. W tym przypadku można wyróżnić metody oparte na logice rozmytej [27][1], uczeniu maszynowym [47] oraz metody oparte na algorytmach genetycznych [44][22][41].

W [12] opisano sposób optymalizacji pracy baterijnego magazynu energii i hybrydowych pojazdów elektrycznych typu plug-in (PHEV) za pomocą systemu zarządzania energią. Do optymalizacji wykorzystano algorytm SMA (ang. Slime Mould Algorithm), a jako funkcję celu przyjęto minimalizację kosztów operacyjnych sieci lokalnej, z uwzględnieniem

kosztów eksploatacji, konserwacji i dziennego kosztu bateryjnego magazynu energii. Autorzy stwierdzili, że zastosowanie algorytmu SMA pozwoliło na znaczną redukcję kosztów operacyjnych mikrosieci przy jednoczesnym zachowaniu stabilności dostaw energii.

W artykule [23] opisano optymalne zarządzanie mikrosiecią wyposażoną w OZE, ogniwo paliwowe, mikroturbinę gazową, generator diesla oraz pojazdy elektryczne, pod kątem minimalizacji kosztów eksploatacji i emisji zanieczyszczeń. Jako algorytm optymalizacji wykorzystano algorytm (ISFLA) (ang. Improved Shuffled Frog Leaping Algorithm), który osiągnął lepsze wyniki (niższy koszt końcowy i krótszy czas obliczeń) w porównaniu do innych popularnych metod, takich jak: Algorytm Genetyczny (GA), czy Algorytm Roju Cząstek (PSO).

Z kolei autorzy w publikacji [30] zamodelowali w środowisku MATLAB/Simulink hybrydowy system zasilania składający się z paneli fotowoltaicznych, turbin wiatrowych, bateryjnego magazynu energii. Opracowano i porównano trzy różne metody optymalizacji /sterowania magazynem energii: system oparty na regułach (RB), optymalizację z wykorzystaniem algorytmu genetycznego (GA) oraz optymalizację z wykorzystaniem symulowanego wyżarzania (SSA) Algorytm GA okazał się najskuteczniejszy, a zastosowanie go pozwoliło na obniżenie kosztów operacyjnych aż o 40% w porównaniu do metody RB.

W artykule [3] opisano możliwości skutecznej minimalizacji kosztów energii elektrycznej za pomocą algorytmu roju cząstek (PSO) w gospodarstwach domowych, złożonego z systemu oraz pikoturbiny wodnej, wykorzystującego dynamikę cen energii. Skuteczność proponowanego rozwiązania została zweryfikowana za pomocą symulacji obejmujących pełny rok kalendarzowy, co pozwoliło na analizę efektywności systemu w różnych porach roku.

W pracy [44] zaproponowano wykorzystanie algorytmu genetycznego do optymalizacji pracy domowego systemu zarządzania energią, złożonego z systemu fotowoltaicznego i magazynu energii. Do rozwiązania problemów optymalizacyjnych wykorzystano algorytm genetyczny, który zapewnia pożądany stan naładowania akumulatora na koniec dnia w oparciu o prognozę na dzień następny. Przeprowadzono analizę porównawczą z rozwiązaniem opartym na taryfach, oceniając całkowity koszt, wymianę energii i moc szczytową. Przeprowadzone badania symulacyjne dowiodły, że zaawansowane algorytmy predykcyjne uwzględniające prognozy generacji i obciążenia znacząco przewyższają efektywnością klasyczne sterowanie regułowe. Elastyczne dobieranie końcowego SOC w oparciu o prognozy pozwala na dalsze oszczędności kosztów lub zwiększenie niezależności energetycznej.

W pracy [56] ciekawe przedstawiono podejście do zarządzania stroną popytu (DSM) za pomocą inteligentnych sieci energetycznych zintegrowanych z odnawialnymi źródłami energii. Celem problemu optymalizacji była jednoczesna minimalizacja kosztów zużycia energii elektrycznej oraz maksymalizacja komfortu odbiorców, rozumianego jako miara stopnia w jakim harmonogram narzucony przez algorytm optymalizacji pokrywa się z preferencjami użytkownika końcowego. Do wyznaczenia optymalnego harmonogramu pracy urządzeń zastosowano algorytm hybrydowy, stanowiący połączenie algorytmu genetycznego (GA) oraz optymalizacji rojem cząstek (PSO). Weryfikację skuteczności metody przeprowadzono w oparciu o symulację w 24-godzinym horyzoncie czasowym.

W pracy [37] zaproponowano hybrydową metodę sterowania magazynem energii jako hybrydę algorytmu genetycznego (GA) z programowaniem dynamicznym (DP). Takie podejście pozwoliło na precyzyjniejsze wyznaczanie harmonogramu pracy przy jednoczesnym ograniczeniu przestrzeni poszukiwań i złożoności obliczeniowej w porównaniu do klasycznego programowania dynamicznego. Autorzy wykazali skuteczność tego podejścia w minimalizacji kosztów zakupu energii dla odbiorców objętych taryfami strefowymi.

W pracy [45] autorzy wykorzystują algorytm PSO do wielokryterialnej optymalizacji hybrydowej systemu zasilania słoneczno-wiatrowego z magazynem energii. Autorzy wykazują, że przy małych różnicach cenowych w ciągu, zyski z samego arbitrażu są niewielkie i mogą zostać całkowicie skonsumowane przez koszt zużycia baterii.

Obok klasycznych metod ewolucyjnych (GA) i rojowych (PSO), coraz szersze zastosowanie znajdują nowsze algorytmy inspirowane naturą. Przykładem jest praca [67], w której do wielokryterialnej optymalizacji harmonogramu mikrosieci wykorzystano ulepszony algorytm GWO (ang. Grey Wolf Optimizer) pod kątem redukcji emisji zanieczyszczeń i obniżenia kosztów energii.

Najnowszy nurt w literaturze dotyczącej Systemów Zarządzania Energią to rozwój metod Głębokiego Uczenia ze Wzmocnieniem (DRL) [24][32][40][68]. W tych metodach nie wymaga się modelu matematycznego funkcji celu, ponieważ „agent AI” uczy się optymalnej strategii sterowania poprzez interakcje ze środowiskiem. Mimo dużego potencjału, metody te działają na zasadzie „czarnej skrzynki”, co jest główną barierą wdrożeniową w przemyśle energetycznym.

2.3. Wnioski wynikające z przeglądu literatury

Na podstawie przeprowadzonego przeglądu literatury można stwierdzić, że najpopularniejszym zastosowaniem systemów zarządzania energią jest możliwość redukcji

kosztów zużycia energii w systemie i zwiększenie wykorzystania energii na potrzeby własne. Jest to złożone zagadnienie optymalizacyjne, które wymaga stosowania takich metod, aby możliwe było znalezienie najbardziej korzystnego harmonogramu pracy magazynu energii.

Przedstawione w przeglądzie metody i algorytmy optymalizacji w różnych systemach wykorzystujących źródła OZE i magazyny energii, ze szczególnym uwzględnieniem systemów solarno-wiatrowych, to tylko niewielka część tego typu systemów. Taki stan rzeczy wynika z bardzo dużej popularności tego typu systemów, mnogości algorytmów optymalizacyjnych oraz dużej liczby zarówno artykułów, jak i innych prac naukowych podejmujących zagadnienia związane z tym tematem. Na tej podstawie można sformułować następujące wnioski:

- Zagadnienie harmonogramowania pracy magazynu energii jest aktualnym problemem, którym zajmuje się wiele zespołów badawczych na całym świecie. Problem ten rozpatruje się przede wszystkim dla wielkoskalowych systemów, takich jak hybrydowych czy Wirtualnych Elektrowni (VPP). Niedostatecznie rozpoznany obszar pozostaje optymalizacja zarządzania energią w lokalnych mikrosieciach prosumenckich, uwzględniająca ich specyficzne ograniczenia techniczne i ekonomiczne[34][11][44][22].
- Większość analiz dostępnych w literaturze[56][34][69] kończy się na etapie wyznaczenia optymalnego harmonogramu przy założeniu idealnej prognozy (faza planistyczna). Istotną luką badawczą jest brak weryfikacji ex-post, która uwzględniałaby sprawdzenie wyznaczonego planu z rzeczywistymi profilami wytwarzania. Pominięcie tego etapu prowadzi do przeszacowania korzyści ekonomicznych, ponieważ nie uwzględnia się kosztów niezbilansowania wynikających z nieuniknionych błędów predykcji.
- Istotnym ograniczeniem części analizowanych prac jest uproszczone podejście do rynku energii. W wielu przypadkach rzeczywista dynamiczna cena energii zastępowana jest taryfami statycznymi lub strefowymi [37][14][69][44][22], co nie oddaje charakterystyki obecnego rynku energii w Polsce. Takie uproszczenie uniemożliwia pełne wykorzystanie potencjału arbitrażu cenowego (dynamiki cen), kluczowego dla rynków o dużej zmienności, takich jak polski rynek energetyczny. Pominięcie gwałtownych fluktuacji cenowych w połączeniu z 15-minutowym okresem rozliczeniowym stanowi istotną barierę w przenoszeniu rozwiązań teoretycznych do praktyki inżynierskiej.
- Istotnym brakiem w wielu publikacjach, [44][11][22][14] jest ograniczona weryfikacja algorytmów optymalizacji, ograniczona do krótkich horyzontów czasowych (np. wybrany dzień lub reprezentatywny tydzień). Takie podejście pomija wpływ sezonowej zmienności wytwarzania energii w OZE, co prowadzi do błędnych szacunków wskaźników

ekonomicznych (np. rocznej stopy zwrotu). Przeprowadzenie badań dla pełnego roku kalendarzowego (z uwzględnieniem wszystkich pór roku i ekstremów pogodowych), jest niezbędne do rzetelnej oceny stabilności i efektywności proponowanej strategii sterowania.

3. CEL, ZAKRES I TEZA PRACY

3.1. Cel pracy

Celem rozprawy doktorskiej jest opracowanie i zbadanie działania zaawansowanego algorytmu harmonogramowania pracy magazynu energii zintegrowanego z odnawialnymi źródła energii w Hybrydowym Systemie Zasilania. Zadaniem algorytmu będzie optymalizacja przepływu energii elektrycznej zarówno wewnątrz lokalnej sieci elektroenergetycznej hybrydowego systemu zasilania, jak i pomiędzy siecią elektroenergetyczną, a hybrydowym systemem zasilania.

3.2. Zakres pracy

Zakres pracy obejmuje:

- Opracowanie modelu matematycznego Hybrydowego Systemu Zasilania (HSZ), uwzględniającego charakterystyki techniczne instalacji fotowoltaicznej, turbiny wiatrowej, profilu obciążenia oraz elektrochemicznego magazynu energii.
- Opracowanie autorskiej metodyki sterowania magazynem energii opartej na sztucznej inteligencji, integrującej moduł predykcyjny z algorytmem optymalizacji harmonogramu pracy, uwzględniającym dynamiczne ceny rynkowe oraz nieliniowe koszty degradacji ogniów
- Przeprowadzenie wielowariantowych badań symulacyjnych w warunkach idealnej prognozy, w celu wyznaczenie optymalnych parametrów konfiguracyjnych magazynu energii (pojemność magazynu oraz stan naładowania na koniec dnia).
- Walidację skuteczności zaproponowanego rozwiązania w warunkach rzeczywistych poprzez analizę porównawczą z deterministycznymi metodami sterowania (algorytm regułowy RB).


3.3. Teza pracy

Wykorzystanie zaawansowanych algorytmów opartych na metodach sztucznej inteligencji do harmonogramowania pracy magazynu energii, w hybrydowym systemie zasilania typu on-grid, wpływa na istotną poprawę wskaźników ekonomicznych pracy systemu, pod warunkiem zastosowania magazynu energii o odpowiedniej pojemności.

4. AUTORSKI ALGORYTM HARMONOGRAMOWANIA PRACY MAGAZYNU ENERGII ZINTEGROWANY Z HYBRYDOWYM SYSTEMEM ZASILANIA

4.1. Algorytm harmonogramowania

Do rozwiązywania problemu optymalizacji harmonogramu pracy magazynu energii zaproponowano autorski algorytm sterowania, którego schemat blokowy przedstawiono na Rys.4.1.



Rys. 4.1. Schemat blokowy algorytmu optymalnego sterowania pracą magazynu energii w hybrydowym systemie zasilania

Zadaniem algorytmu jest sterowanie pracą magazynu energii w taki sposób, aby gromadzić energię elektryczną w okresach niskich cen sprzedaży, a oddawać ją do sieci wtedy, kiedy cena osiąga wartość maksymalną. Stąd, to algorytm decyduje o jednym z trzech stanów pracy magazynu - ładowanie, rozładowanie lub spoczynek. Dzięki temu wybierany jest optymalny stan pracy układu, jednocześnie wpływając na wzrost zysków sprzedaży energii elektrycznej oraz wzrost rentowności całego systemu zasilania. Zaproponowano, że algorytm będzie sterował hybrydowym systemem zasilania złożonym ze źródeł OZE (wiatrak oraz panele PV), magazynu energii elektrycznej oraz symulowanego obciążenia sieci.

Jak wynika ze schematu (Rys. 4.1.), w celu wyznaczenia optymalnych warunków działania magazynu, zaproponowany algorytm korzysta z następujących danych wejściowych:

- Prognozowanych danych meteorologicznych (prognozę temperatury, natężenia promieniowania słonecznego i prędkości wiatru).
- Danych rynkowych - cena zakupu c_{buy_t} oraz cena sprzedaży c_{sell_t} energii elektrycznej,
- Danych o obciążeniu lokalnym – harmonogram pracy obciążeń lokalnych E_{LOAD_t} ,
- Danych o ograniczeniach i parametrach znamionowych magazynu energii (pojemność, moc znamionową, dopuszczalna głębokość rozładowania oraz sprawność cyklu itp.) – dane dodatkowe.

Funkcja celu dla opracowanego algorytmu optymalizacji wyrażona jest wzorem (4.1):

$$\max F(E_{BESS}) = \begin{cases} \sum_{t=1}^n (E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) \cdot c_{sell_t} - |E_{BESS_t}| \cdot c_{cost}, (E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) \geq 0 \\ \sum_{t=1}^n (E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) \cdot c_{buy_t} - |E_{BESS_t}| \cdot c_{cost}, (E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) < 0 \end{cases} \quad (4.1)$$

gdzie:

E_{RES_t} – energia generowana przez OZE w okresie t, gdzie $E_{RES_t} = E_{PV_t} + E_{WT_t}$,

E_{PV_t} – energia generowana przez system fotowoltaiczny w okresie t, E_{WT_t} – energia generowana przez system wiatrowy w okresie t,

E_{LOAD_t} – energia zużywana przez lokalne obciążenie w okresie t,

E_{BESS_t} – energia pobierana z systemu magazynowania energii (ze znakiem +) lub dostarczana do niego (ze znakiem -) w okresie t,

c_{sell_t} – cena sprzedaży energii elektrycznej w okresie t,

c_{buy_t} – cena zakupu energii elektrycznej w okresie t,

c_{cost} – koszty operacyjne magazynu energii, kWh/PLN.

Założono, że funkcja celu osiąga wartość maksymalną w przypadku otrzymania maksymalnej wartości zysku ze sprzedaży energii elektrycznej. Dzieje się to wtedy, kiedy wartość rynkowa energii (iloczyn energii wytworzonej z OZE i/lub energii pobieranej z magazynu z ceny dynamicznej energii) przewyższa koszt energii dla lokalnego

zapotrzebowania sieci. Dlatego bardzo istotnym elementem strategii działania algorytmu optymalizacji jest wykorzystywanie dynamicznie zmieniających się cen energii elektrycznej. Zaproponowana w równaniu (4.1) funkcja celu maksymalizuje bilans ekonomiczny wymiany energii z siecią elektroenergetyczną, który jest pomniejszony o koszty pracy magazynu energii w analizowanym okresie n . Optymalizowana funkcja jest sumą kosztów i przychodów dla okresu n , które obliczane są dla każdego kroku czasowego t . Zaproponowana funkcja celu (4.1) rozpatruje trzy stany pracy hybrydowego systemu zasilania, które decydują o tym, czy w danej chwili t , występuje stan nadwyżki, deficytu lub równowagi.

W pierwszym przypadku suma energii generowanej z OZE i energii pobieranej (lub oddawanej) z magazynu jest większa niż zapotrzebowanie obciążenia lokalnego, czyli $(E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) > 0$ – powstaje nadwyżka, której wielkość może być sprzedana do sieci elektroenergetycznej po cenie c_{sell} , co generuje zysk.

W drugim przypadku suma energii generowanej z OZE i energii pobieranej (lub oddawanej) z magazynu jest mniejsza niż zużycie, czyli: $(E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) < 0$ – powstaje deficyt, który skutkuje koniecznością kupna energii z sieci elektroenergetycznej po cenie c_{buy} , co generuje koszt.

Trzeci przypadek, to ten, w którym suma energii wytwarzanej z OZE i pobieranej (lub oddawanej) z magazynu jest równa zapotrzebowaniu, czyli $(E_{RES_t} + E_{LOAD_t} + E_{BESS_t}) = 0$ – w tym przypadku układ jest w równowadze, nie ma wymiany energii z siecią.

Poszukiwanie optymalnego sposobu sterowania magazynem energii odbywa się z uwzględnieniem całkowitego bilansu energetycznego lokalnego systemu oraz ograniczeń fizycznych magazynu energii. W tym celu, należy określić parametry pracy magazynu energii do których należą: maksymalna moc ładowania i rozładowania oraz całkowita pojemność energii. Wymienione parametry stanowią ograniczenia dla zdefiniowanej funkcji celu (4.1). Stąd też, w przypadku każdego okresu symulacji średnia dopuszczalna energia, za pomocą której magazyn może zostać naładowany $E_{BESS,charg}$ lub rozładowany $E_{BESS,disch}$ jest zdefiniowana jako ograniczenie w postaci:

$$E_{BESS,charg} - E_{BESS_t} \leq 0, \forall t \in \{1, \dots, n\} \quad (4.2)$$

$$E_{BESS_t} - E_{BESS,discharg} \leq 0, \forall t \in \{1, \dots, n\} \quad (4.3)$$

Bieżąca wartość energii w systemie magazynowania obliczana jest w każdym kroku na podstawie stanu z poprzedniego bilansu, uwzględniając odpowiednie sprawności konwersji energii, niezależnie, czy był to proces ładowania, czy rozładowania,:

$$E_t = \begin{cases} E_{t-1} - \eta_{ch} E_{BESS_t}, & E_{BESS_t} < 0 \\ E_{t-1} \cdot \frac{E_{BESS_t}}{\eta_{dis}}, & E_{BESS_t} > 0, \forall t \in \{1, \dots, n\} \\ E_{t-1}, & E_{BESS_t} = 0 \end{cases} \quad (4.4)$$

W przypadku pobierania energii przez magazyn $E_{BESS_t} < 0$, ilość energii faktycznie magazynowanej jest pomniejszona o straty wynikające ze sprawności ładowania η_{ch} . Natomiast w przypadku oddawania energii z magazynu $E_{BESS_t} > 0$, jej ilość oddawana do sieci musi zostać powiększona o straty wynikające ze sprawności rozładowania wyrażanej przez współczynnik η_{dis} .

Aktualny stan naładowania magazynu energii może być wyrażony wzorem (4.5):

$$SoC_t = E_t \frac{1}{E_{max}} \cdot 100\%, \forall t \in \{1, \dots, n\} \quad (4.5)$$

Ograniczenia techniczne magazynu energii obejmują również jego maksymalną pojemność E_{max} (4.6) oraz dopuszczalną głębokość rozładowania E_{min} (4.7):

$$E_t - E_{max} \leq 0, \forall t \in \{1, \dots, n\} \quad (4.6)$$

$$E_{min} - E_t \leq 0, \forall t \in \{1, \dots, n\} \quad (4.7)$$

Istotnym elementem opracowania sposobu harmonogramowania pracy magazynu energii w systemie cyklicznym jest zdefiniowanie warunku końcowego, czyli ilość energii w magazynie na koniec dnia.

$$(E_{end} - Tol_{end}) - E_n \leq 0 \quad (4.8)$$

Wprowadzenie takiego ograniczenia zapobiega sytuacji, w której algorytm optymalizacji bezwzględnie dąży do maksymalizacji wyniku finansowego w bieżącym oknie czasowym. Takie działanie, może prowadzić do całkowitego rozładowania magazynu na koniec okresu harmonogramowania (np. na koniec dnia, czyli 24 godzinne okna czasowego). Brak ograniczenia (4.8) uniemożliwiałby optymalne sterowanie magazynem na początku kolejnego horyzontu czasowego (24 h). Dodatkowo przyjęcie tolerancji Tol_{end} zwiększa stabilność numeryczną algorytmu optymalizacji, co ułatwia znalezienie rozwiązania dopuszczalnego w skończonym czasie. Dopuszczalna odchyłka Tol_{end} stanu naładowania magazynu energii na koniec dnia zapobiega nieefektywnemu ekonomicznie wymuszaniu ładowania lub rozładowania magazynu w ostatnich krokach symulacji (dnia), gdy ceny energii mogą być niekorzystne. Dla wykonywanych symulacji przyjęto stały parametr $Tol_{end}=0,5$ kWh.

Ciągła praca magazynu, zarówno proces ładowania jak i rozładowywania, wpływa na zmniejszenie jego pojemności. Związane jest to z występowaniem następujących zjawisk: wzrost warstwy SEI (Solid Electrolyte Interphase), pękanie cząstek materiału. W celu uwzględnienia kosztów degradacji magazynu energii dla funkcji celu (4.1) wprowadzono koszty operacyjne magazynu energii, które zdefiniowano jako c_{cost} . W funkcji celu (4.1) koszty te są mnożone przez wartość bezwzględną przepływu energii z magazynu.

Koszty operacyjne obliczane są jako stosunek kosztu zakupu magazynu energii elektrycznej do iloczynu jego maksymalnej pojemności i maksymalnej liczby cykli pracy.

$$c_{cost} = \frac{\text{koszt zakupu systemu}}{\text{ilość cykli} * \text{pojemność magazynu energii} * 2} \quad (4.9)$$

Przyjęto, że jeden cykl pracy składa się zarówno z fazy ładowania i rozładowania, dlatego funkcja celu (4.1) uwzględnia przepływ energii w obu kierunkach. Z tego względu w mianowniku wprowadzono stałą 2. Natomiast iloczyn maksymalnej pojemności i maksymalnej liczby cykli przedstawia całkowitą ilość energii, jaką magazyn energii może zmagazynować w całym okresie eksploatacji.

Problem optymalnego harmonogramowania pracy magazynu energii jest zadaniem złożonym, ponieważ może charakteryzować się znacznym, stopniem nieliniowości i duża przestrzenią poszukiwań rozwiązań optymalnych. Dlatego w celu rozwiązania funkcji (4.1), zastosowano metodę algorytmu genetycznego (GA). Algorytm genetyczny cechuje się zdolnością do globalnej eksploracji i unikania minimów lokalnych.

Algorytm genetyczny został zaimplementowany w środowisku *Matlab* przy wykorzystaniu biblioteki *Global Optimization Toolbox*. Środowisko to wybrano ze względu na dostępność zaawansowanych i zweryfikowanych numerycznie istniejących już algorytmów.

Do implementacji GA wykorzystano funkcję *ga* dostępną w środowisku *Matlab*, którą skonfigurowano na potrzeby tej pracy. Parametryzację zrealizowano wykorzystując strukturę *optimoptions*, za pomocą, której dobrano kluczowe nastawy, dzięki którym uzyskano zbieżność obliczeń w zadanym, akceptowalnym czasie wynoszącym do 5 minut obliczeń dla jednego dnia. Aby zapewnić balans pomiędzy eksploatacją przestrzeni rozwiązań, a czasem obliczeń, przyjęto następujące parametry dla algorytmu genetycznego - tabela 4.1.

Tabela 4.1. Konfiguracja parametrów dla GA

Parametr funkcji <i>ga</i>	Ustawienie parametru	Opis i uzasadnienie
<i>PopulationSize</i>	500	Liczebność populacji dobierana eksperymentalnie, aby zapewnić różnorodność genetyczną.
<i>MaxGenerations</i>	100	Maksymalna liczba iteracji algorytmu GA
<i>MaxStallGenerations</i>	10	Kryterium stopu (algorytm się zatrzyma, jeśli przez podaną liczbę pokoleń nie będzie poprawy funkcji celu)
<i>EliteCount</i>	50	Liczba najlepszych osobników z obecnego pokolenia, które przechodzą do następnego pokolenia bez zmian.
<i>MaxTime</i>	300 s	Limit czasu obliczeń.
<i>FunctionTolerance</i>	10^{-6}	Poniżej progu tolerancji, zmiany wartości funkcji celu są uznawane za niestotne.
<i>HybridFcn</i>	<i>fmincon</i>	Funkcja hybrydująca. Po zakończeniu działania GA, wynik końcowy staje się punktem startowym dla algorytmu <i>fmincon</i> .


Ponieważ ostateczna korzyść finansowa w dużej mierze zależy od jakości danych wejściowych opisujących przyszłe warunki pracy systemu, stąd cenę energii oraz profil zapotrzebowania na nią przyjmuje się jako zdefiniowane parametry, natomiast wielkość przewidywanego wytwarzania energii elektrycznej z OZE wymaga zastosowania zaawansowanych metod predykcji, ze względu na zależność od warunków atmosferycznych. W związku z tym, ważnym elementem jest zastosowany moduł predykcji, który prognozuje przyszłą generację energii na podstawie dostępnych jednodniowych prognoz pogody z serwisu meteorologicznego [58]. Klasyczne rekurencyjne sieci neuronowe posiadają jedynie „pamięć krótkotrwałą” i mogą wykazywać problem niestabilnego gradientu. Mając to na uwadze zastosowano sieci Long Short-Term Memory (LSTM) będące rodzajem rekurencyjnych sieci neuronowych charakteryzujących się długą pamięcią krótkich wzorców. W przeciwieństwie do klasycznych rekurencyjnych sztucznych sieci neuronowych, sieci LSTM wykazują lepsze właściwości do przetwarzania całych sekwencji danych. Sieci te nie traktują każdej wartości w sekwencji niezależnie, ale w dodatku przechowują użyteczne informacje o poprzednich danych. Proces uczenia sieci LSTM jest tożsamy z procesem uczenia zwykłych rekurencyjnych SSN i polega na doborze wag sieci poprzez minimalizację funkcji błędu, wykorzystując dane uczące w postaci par (wielkość wejściowa i wielkość zadana na wyjściu). Do tego celu wykorzystuje się metodę gradientową z algorytmem propagacji wstecznej. Sieć LSTM skonfigurowano w pakiecie MATLAB za pomocą toolboxa *Deep Network Designer*. Konfiguracje parametrów dla zastosowanych sieci LSTM przedstawiono w tabeli 4.2.

Tabela 4.2. Konfiguracja parametrów sieci LSTM

Parametr	Parametry LSTM dla PV	Parametry LSTM dla WT
Typ sieci	Jednowarstwowa LSTM	Jednowarstwowa LSTM
Liczba wejść	2 (Temperatura, Nasłonecznienie)	1 (Prędkość wiatru)
Liczba wyjść	1 (Moc PV)	1 (Moc WT)
Liczba neuronów ukrytych	128	128
Algorytm optymalizacji	Adam	Adam
Maksymalna liczba epok	100	100
Współczynnik uczenia	0.01 (Stały)	0.01 (Stały)
Próg gradientu	1	1
Funkcja błędu	MSE (błąd średniokwadratowy)	MSE (błąd średniokwadratowy)

4.2. Implementacja algorytmu harmonogramowania

Schemat blokowy działania algorytmu optymalizacji przedstawiono na Rys. 4.2. Opracowany algorytm realizuje strategię sterowania w pętli iteracyjnej i obejmuje N symulacji, gdzie N oznacza liczbę dni. Założono, że dla pojedynczej doby krok obliczeniowy wynosi 15 min, co w sumie daje 96 okresów decyzyjnych (kroków) na dzień.



Rys. 4.2. Schemat blokowy algorytmu optymalizacji

W pierwszym kroku program definiuje parametry techniczno-ekonomiczne analizowanego Hybrydowego Systemu Zasilania (HSZ). Wczytuje parametry znamionowe magazynu energii zgodnie z tabelą 4.3.

Tabela 4.3. Wejściowe parametry techniczno-ekonomiczne dla HSZ

Zmienna	Jednostka	Opis
E_{BESS}	kWh	Pojemność znamionowa magazynu energii.
E_1	kWh	Energia początkowa. Stan naładowania w chwili $t=1$. (np. SoC=50%)
E_{end}	kWh	Wymagany stan naładowania po zakończeniu cyklu (np. na koniec horyzontu czasowego/dnia).
Tol_{end}	kWh	Dopuszczalne odchylenie od E_{end} na koniec horyzontu czasowego/dnia.
E_{max}	kWh	Maksymalna dopuszczalna energia w magazynie. (np. 90% pojemności znamionowej, aby chronić przed przeładowaniem).
E_{min}	kWh	Minimalna dopuszczalna energia w magazynie (np. 10% pojemności znamionowej, aby chroni przed głębokim rozładowaniem).
η_{dis}	-	Sprawność rozładowania magazynu energii.
η_{ch}	-	Sprawność ładowania magazynu energii.
c_{cost}	PLN/kWh	Jednostkowy koszt użycia jako koszt degradacji magazynu energii.

Dodatkowo przed rozpoczęciem symulacji zadawany jest dzień początkowy oraz liczba dni, dla których ma być przeprowadzona symulacja pracy HSZ.

W drugim kroku program pobiera dane wejściowe z zewnętrznego pliku (arkusza kalkulacyjnego) dla zadanego horyzontu czasowego. Dane te obejmują:

- wczytanie profili wytwarzania energii źródeł OZE (rzeczywistych),
- wczytanie danych prognoz pogodowych (w celu wygenerowania prognoz generacji z OZE),
- wczytanie profili dynamiki cen energii elektrycznej,
- wczytanie profilu obciążenia lokalnego.

Szczegółowe dane wczytywane przez program pokazano w Tabeli 4.4.

Tabela 4.4. Dane wejściowe do symulacji działania algorytmu optymalizacji: Profile generacji OZE, zapotrzebowania na energię oraz prognozowanych warunków meteorologicznych (prognoza 1 dniowa)

Zmienna	Jednostka	Opis
E_{PV_t}	kWh	Ilość energii wyprodukowanej przez system fotowoltaicznym w danym kroku czasowym (np. 15 min).
E_{WT_t}	kWh	Ilość energii wyprodukowanej przez system wiatrowy w danym kroku czasowym (np. 15 min).
E_{LOAD_t}	kWh	Ilość energii zużytej przez odbiorniki lokalne w danym kroku czasowym (np. 15 min).
$Temp$	°C	Średnia prognozowana wartość temperatury otoczenia w danym kroku czasowym (np. 15 min).
$Wind$	m/s	Średnia prognozowana wartość prędkości wiatru w danym kroku czasowym (np. 15 min).
Irr	W/m ²	Średnia prognozowana wartość natężenie promieniowania słonecznego w danym kroku czasowym (np. 15 min).
c_{sell_t}	PLN/kWh	Cena sprzedaży energii elektrycznej w danym kroku czasowym.
c_{buy_t}	PLN/kWh	Cena zakupu energii elektrycznej w danym kroku czasowym.

Wczytanie parametrów techniczno-ekonomicznych dla HSZ (Tabela 4.3.) oraz danych wejściowych (Tabela 4.4.) powoduje przejście algorytmu do głównej pętli iteracyjnej. Pętla ta realizowana jest dla każdego kolejnego dnia symulacji $d=1,...,N$. Iteracja w pętli głównej programu dla pojedynczego kroku przebiega następująco:

- Przygotowanie nowego wektora na podstawie pobranych danych wejściowych (tabela 4.3), który odpowiada bieżącemu horyzontowi czasu. Do symulacji przyjęto 24 godzinny horyzont czasu (zaczynający się o godz. 00:00 i trwający do godz. 00:00) dnia następnego z rozdzielczością 15 minutową (96 kroków).
- Wczytane parametry stanowią podstawę do sformułowania zadania optymalizacyjnego dla symulowanego dnia. Dodatkowo następuje nałożenie ograniczeń wynikających z parametrów znamionowych magazynu energii oraz innych założeń.
- W kolejnym korku następuje predykcja generacji z instalacji OZE dla aktualnie symulowanego dnia.

- W kolejnym etapie następuje proces wyznaczenia sterowania optymalnego dla magazynu energii. Algorytm genetyczny rozwiązuje problem zdefiniowany przez funkcje celu (4.1). Celem algorytmu genetycznego jest wyznaczenie optymalnego wektora sterowań dla magazynu energii, które maksymalizują zysk hybrydowego systemu zasilania, przy przestrzeganiu ograniczeń technicznych. W problemach harmonogramowania pracy magazynu energii, które charakteryzują się licznymi ograniczeniami (np. stan naładowania magazynu, moc magazynu) losowa inicjalizacja populacji mogłaby prowadzić do generowania dużej liczby rozwiązań niespełniających ograniczeń w kilku pierwszych generacjach co technicznie spowalniałoby proces zbieżności algorytmu. Aby zniwelować ten efekt zaproponowano inicjalizację populacji początkowej jako grupę trzech podzbiorów. Pierwszy osobnik jest wynikiem działania algorytmu regułowego. Takie działanie ma na celu zapewnienie, że już w pierwszej iteracji algorytmu w populacji znajduje się rozwiązanie poprawne. Drugą podgrupę stanowiącą ~20% populacji stanowią osobniki, które powstają na skutek mutacji pierwszego osobnika poprzez dodanie do jego wektora sterowań szumu o rozkładzie normalnym – wykorzystanie w Matlabie funkcji *randn*. Ta podgrupa odpowiada za poszukiwanie sąsiedniego rozwiązania w otoczeniu rozwiązania bazowego i jest tworzona wg wzorów:

$$\check{E}_{BESS}^i = E_{RB} + N(0, \sigma^2) \cdot 0,15 \cdot E_{BESS,charg} \quad (4.10)$$

$$E_{BESS}^i = \begin{cases} E_{BESS,discharg} & E_{BESS}^i < E_{BESS,discharg} \\ \check{E}_{BESS}^i & E_{BESS,discharg} \leq E_{BESS}^i \leq E_{BESS,charg} \\ E_{BESS,charg} & E_{BESS}^i > E_{BESS,charg} \end{cases} \quad (4.11)$$

Gdzie:

E_{BESS}^i - wektor sterujący i-tego osobnika w podgrupie,

E_{RB} - wektor bazowy (wynik algorytmu RB),

$N(0, \sigma^2)$ – wektor losowy o rozkładzie normalnym,

$E_{BESS,charg}$ - średnia dopuszczalna energia ładowania magazynu energii,

$E_{BESS,discharg}$ - średnia dopuszczalna energia rozładowania magazynu energii,

Natomiast trzecia podgrupa stanowiąca ~80% populacji generowana jest w sposób losowy z rozkładem jednostajnym (funkcja *rand* z Matlab) z uwzględnieniem

ograniczeń wynikających z parametrów znamionowych magazynu energii (w granicach mocy wyjściowej magazynu energii).

$$E_{BESS}^i = E_{BESS,discharg} + (E_{BESS,charg} - E_{BESS,discharg}) \cdot U(0,1) \quad (4.12)$$

Gdzie:

$U(0,1)$ - wektor losowy o rozkładzie jednostajnym w przedziale $[0,1]$.

Trzecia podgrupa odpowiada za utrzymanie różnorodności rozwiązań i jednocześnie zapobiega przedwczesnej zbieżności algorytmu do minimum lokalnego, którym może być rozwiązanie obliczone przez algorytm regułowy. Tak przygotowane pokolenie startowe przekazywane jest do algorytmu genetycznego.

- W kolejnym kroku następuje rozwiązanie problemu optymalizacji przez algorytm optymalizacji GA. Każde nowe pokolenie tworzone jest w następujący sposób: najlepszych rozwiązań z poprzedniej generacji przechodzi do nowej bez żadnych zmian – tzw. Elita. Gwarantuje monotoniczność procesu optymalizacji (brak utraty najlepszego znalezionego rozwiązania). Dla 80% pozostałej populacji przeprowadzona jest selekcja rodziców i krzyżowanie. Proces ten odpowiada za wymianę informacji genetycznej i łączenie cech osobników. Pozostałe 20% rozwiązań poddawane jest mutacji i wprowadzane są do nich zmiany. Wielkość zmiany (mutacji) maleje wraz z kolejnymi pokoleniami. Celem algorytmu genetycznego jest wyznaczenie optymalnego harmonogramu pracy magazynu energii (dla każdego z 96 kroków) z uwzględnieniem ograniczeń. Algorytm genetyczny kontynuuje obliczenia, dopóki nie zostanie spełniony jeden ze zdefiniowanych warunków zakończenia (Tab.4.1). Po zakończeniu warunku końcowego, najlepszy osobnik z populacji końcowej stanowi punkt startowy dla deterministycznego algorytmu gradientowego (funkcja *fmincon* w Matlab). Algorytm ten, wykorzystując metody punktu wewnętrznego i precyzyjnie wyznacza lokalne minimum funkcji celu dla rozwiązania GA [15].
- Następnie z obliczonego rozwiązania odczytywany jest stan naładowania magazynu energii w ostatnim kroku. Aby zapewnić możliwość symulacji pracy z systemu dla długiego okresu (np. rok) końcowy stan naładowania magazynu energii jest przypisywany jako warunek początkowy dla dnia następnego wg wzoru:

$$E_1(\text{dzień} + 1) = E_{\text{end}}(\text{dzień}) \quad (4.13)$$

- Otrzymane wyniki zapisywane są w formie pliku excel w dwóch formach - przebiegów dla każdego kroku czasowego (Tab. 4.5.) oraz statystyk (Tab. 4.6.). Po zapisaniu danych algorytm weryfikuje, czy został osiągnięty warunek stopu $d > N$, jeśli nie to pętla programu wraca na początek i algorytm wykonuje obliczenia dla kolejnego dnia, aż do osiągnięcia horyzontu symulacji N .
- Po spełnieniu warunku zakończenia pętli $d = N$ wykonywana jest agregacja wyników statystyk dla wszystkich dni i generowany jest zbiorczy raport końcowy w formie pliku excel.

Tabela 4.5. Dane wyjściowe z symulacji działania algorytmu optymalizacji: prognoza generacji energii z OZE (na podstawie prognoz 1 dniowych), wektor sterowań baterią, bilans energetyczny, SoC baterii

Zmienna	Jednostka	Opis
E_{BESS_t}	kWh	Zmienna decyzyjna. Ilość energii pobieranej z systemu magazynowania energii (ze znakiem +) lub dostarczana do niego (ze znakiem -) w danym kroku czasowym.
$E_{PV\_pred_t}$	kWh	Prognoza ilości generacji energii przez system fotowoltaicznym w danym kroku czasowym (np. 15 min).
$E_{WT\_pred_t}$	kWh	Prognoza ilości generacji energii przez system wiatrowy w danym kroku czasowym (np. 15 min).
E_{GRID_t}	kWh	Bazowy bilans energetyczny HSZ z siecią elektroenergetyczną bez udziału magazynu energii ($E_{PV_t} + E_{WT_t} - E_{LOAD_t}$) w danym kroku czasowym.
$E_{GRID\_pred_t}$	kWh	Prognoza bazowego bilansu energetycznego HSZ z siecią elektroenergetyczną bez udziału magazynu energii ($E_{PV\_pred_t} + E_{WT\_pred_t} - E_{LOAD_t}$) w danym kroku czasowym.
E_{NET_t}	kWh	Zoptymalizowany bilans energetyczny HSZ z siecią elektroenergetyczną z uwzględnieniem magazynu energii ($E_{PV_t} + E_{WT_t} - E_{LOAD_t} + E_{BESS_t}$) w danym kroku czasowym.
$E_{NET\_pred_t}$	kWh	Zoptymalizowany bilans energetyczny HSZ z siecią elektroenergetyczną z uwzględnieniem magazynu energii

		$(E_{PV\_pred_t} + E_{WT\_pred_t} - E_{LOAD_t} + E_{BESS_t})$ w danym kroku czasowym.
SOC_t	%	Stan naładowania magazynu energii w danym kroku czasowym.


Tabela 4.6. Statystyki dzienne i wskaźniki

Zmienna	Jednostka	Opis
$E_{LOAD} = \sum_{t=1}^n E_{LOAD_t}$	kWh	Suma energii zużytej przez odbiorcę w analizowanym okresie.
$E_{RES} = \sum_{t=1}^n E_{RES_t}$	kWh	Suma energii wygenerowanej przez źródła OZE w analizowanym okresie.
$E_{BESS\_sum\_dis} = \sum_{t=1}^n E_{BESS_t} (E_{BESS_t} > 0)$	kWh	Suma energii rozładowania magazynu energii w analizowanym okresie.
$E_{BESS\_sum\_ch} = \sum_{t=1}^n E_{BESS_t} (E_{BESS_t} < 0)$	kWh	Suma energii ładowania magazynu energii w analizowanym okresie.
$E_{NET\_import} = \sum_{t=1}^n E_{NET_t} (E_{NET_t} > 0)$	kWh	Rzeczywisty import (kupno) energii z sieci w analizowanym okresie.
$E_{NET\_export} = \sum_{t=1}^n E_{NET_t} (E_{NET_t} < 0)$	kWh	Rzeczywisty eksport (sprzedaż) energii do sieci w analizowanym okresie.
$E_{NET\_import\_pred} = \sum_{t=1}^n E_{NET\_pred_t} (E_{NET\_pred_t} > 0)$	kWh	Planowany import (kupno) energii z sieci w analizowanym okresie.
$E_{NET\_export\_pred} = \sum_{t=1}^n E_{NET\_pred_t} (E_{NET\_pred_t} < 0)$	kWh	Planowany eksport (sprzedaż) energii do sieci w analizowanym okresie.
$J_{real} = \sum_{t=1}^n E_{NET_t} \cdot c_{buy_t} (E_{NET_t} > 0) +$ $\sum_{t=1}^n E_{NET_t} \cdot c_{sell_t} (E_{NET_t} < 0) +$ $\sum_{t=1}^n E_{BESS_t} \cdot c_{cost}$	PLN	Rzeczywisty wyniki finansowy, uwzględniający całkowity zysk lub koszt (dla wyniku ujemnego) działania systemu HSZ z uwzględnieniem realnych

		przepływów energii oraz kosztów degradacji baterii w analizowanym okresie..
$CF_{real} = \sum_{t=1}^n E_{NET_t} \cdot c_{sell_t}(E_{NET_t} > 0) + \sum_{t=1}^n E_{NET_t} \cdot c_{buy_t}(E_{NET_t} < 0)$	PLN	Rzeczywisty wyniki finansowy, uwzględniający całkowity zysk lub koszt (dla wyniku ujemnego) działania systemu HSZ z uwzględnieniem realnych przepływów energii bez kosztów degradacji baterii w analizowanym okresie..
$J_{ref} = \sum_{t=1}^n (E_{GRID_t}) \cdot c_{sell_t}(E_{GRID_t} > 0) + \sum_{t=1}^n (E_{GRID_t}) \cdot c_{buy_t}(E_{GRID_t} < 0)$	PLN	Referencyjny wynik finansowy, uwzględniający całkowity zysk lub koszt (dla wyniku ujemnego) działania systemu HSZ bez magazynu energii z uwzględnieniem realnych przepływów energii w analizowanym okresie..
$J_{prog} = \sum_{t=1}^n E_{NET\_pred_t} \cdot c_{buy_t}(E_{NET\_pred_t} > 0) + \sum_{t=1}^n E_{NET\_pred_t} \cdot c_{sell_t}(E_{NET\_pred_t} < 0) + \sum_{t=1}^n E_{BESS_t} \cdot c_{cost}$	PLN	Prognozowany wyniki finansowy, uwzględniający całkowity zysk lub koszt (dla wyniku ujemnego) działania systemu HSZ z uwzględnieniem realnych przepływów energii oraz kosztów degradacji baterii w analizowanym okresie..
$\Delta J_{BESS} = J_{real} - J_{ref}$	PLN	Zysk dzięki zastosowaniu magazynu energii w analizowanym okresie.
$\Delta J_{err} = J_{prog} - J_{real}$	PLN	Błąd predykcji wyniku finansowego w analizowanym okresie.
$\Delta J_{err\_ \%} = \frac{J_{prog} - J_{real}}{J_{real}} \cdot 100\%$	%	Względny błąd wyniku finansowego w analizowanym okresie.

5. HYBRYDOWY SYSTEM ZASILANIA TYPU SŁONECZNO-WIATROWEGO Z MAGAZYNEM ENERGII

W celu weryfikacji i przetestowania działania autorskiego algorytmu harmonogramowania pracy magazynu energii, opisanego w Rozdziale 4, niezbędne było opracowanie modelu matematycznego hybrydowego systemu zasilania. W niniejszym rozdziale przedstawiono modele matematyczne zaproponowanych komponentów systemu: system fotowoltaiczny (PV), system turbiny wiatrowej (TW) oraz bateryjny magazyn energii (BESS). Istotnymi elementami modelu są również przekształtniki energoelektroniczne, które służą do konwersji i sterowania przepływami energii między komponentami a siecią. Praca całości systemu była symulowana przy wykorzystaniu pakietów oprogramowania MATLAB/Simulink oraz specjalistycznej biblioteki Simscape Electrical. Ogólny schemat blokowy opracowanego modelu Hybrydowego Systemu Zasilania przedstawiono na Rys. 5.1.



Rys. 5.1. Schemat blokowy opracowanego modelu Hybrydowego Systemu Zasilania.


5.1. Model systemu fotowoltaicznego

Model matematyczny komponentów PV


Podstawowym elementem systemu fotowoltaicznego jest ogniwo słoneczne, będące złączem p-n wytworzone w cienkiej warstwie półprzewodnika. To w ogniwie zachodzi efekt fotowoltaiczny, czyli bezpośrednia konwersja promieniowania słonecznego na energię elektryczną prądu stałego. Moduł fotowoltaiczny składa się z wielu połączonych szeregowo-równolegle ogniw słonecznych. Model matematyczny ogniwa opisany jest za pomocą charakterystyk prądowo-napięciowych (I-V) i mocowo-napięciowych (P-V) zależnych od nasłonecznienia i temperatury ogniwa w sposób nieliniowy.

Przykłady takich charakterystyk przedstawiono na Rys. 5.2., gdzie moc oraz napięcie modułu PV rosną wraz ze wzrostem natężenia promieniowania słonecznego (Rys. 5.2.a) i jednocześnie maleją wraz ze wzrostem temperatury ogniwa (5.2.b).

a)




b)



Rys.5.2. Charakterystyki prądowo-napięciowa oraz mocowo-napięciowa dla przykładowego panelu PV:

- a) temperatura panelu równa 25 °C i zmienne natężenie promieniowania słonecznego
- b) natężenia promieniowania słonecznego równe 1000 W/m² i zmienna temperatura panelu fotowoltaicznego, opracowanie własne na podstawie programu Matlab&Simulink

Jako model ogniwa fotowoltaicznego przyjęto model jednodiodowy, a jego schemat zastępczy przedstawiono na Rys. 5.3. [29]. Jak wynika z Rys. 5.3. model ten składa się z idealnego źródła prądowego (prąd fotodiody), diody oraz rezystancji szeregowej i równoległej.



Rys.5.3. Schemat obwodu zastępczego jednodiodowego ogniwa fotowoltaicznego

Na podstawie prawa Kirchhoffa prąd wyjściowy ogniwa słonecznego w obwodzie zastępczym można wyrazić w postaci (5.1):

$$I = I_{ph} - I_0 \left[\exp \left(\frac{q}{AkT} (U + I \cdot R_s) \right) - 1 \right] - \frac{U + IR_s}{R_p} \quad (5.1)$$

gdzie:

- I_{ph} – prąd generowany przez światło (fotoprąd), A
- I_0 – prąd nasycenia diody, A
- q – ładunek elementarny, $q = 1,602 \cdot 10^{-19}$, C
- A – współczynnik idealności diody (ogniwo idealne $A=1$, dla rzeczywistego $1 < A < 2$)
- k – stała Boltzmana, $k = 1,38 \cdot 10^{-23}$, J/K
- T – temperatura pracy fotoogniwa, T
- U – spadek napięcia na obciążeniu, V
- I – prąd obciążenia, A
- R_s – rezystancja szeregową, Ω
- R_p – rezystancja bocznikowa, Ω

Źródło prądowe wytwarza prąd I_{ph} tzw. fotoprąd, który zależy zarówno od temperatury ogniwa, jak i od natężenia promieniowania słonecznego, co wyraża się wzorem (5.2).:

$$I_{ph} = [\alpha_i(T - T_r) + I_{sc}] \frac{G}{G_{STC}} \quad (5.2)$$

gdzie:

- α_i – współczynnik temperaturowy prądu zwarcia, A/K
- T – temperatura pracy fotoogniwa, T
- T_r – temperatura referencyjna ogniwa, K
- I_{sc} – prąd zwarcia ogniwa w warunkach referencyjnych, A
- G – natężenie promieniowania słonecznego, W/m²
- G_{STC} – referencyjne natężenie promieniowania słonecznego w warunkach STC, W/m²

Natomiast prąd nasycenia diody zależy od temperatury i można go opisać zależnością (5.3.):

$$I_0 = \frac{I_{sc} + \alpha_i(T - T_r)}{\exp \left[(V_{oc} + \beta_v(T - T_{STC})) / A \frac{kT}{q} \right] - 1} \quad (5.3)$$

gdzie:

- I_{sc} – prąd zwarcia ogniwa w warunkach referencyjnych, A
- α_i – współczynnik temperaturowy prądu zwarcia, A/K

- T – temperatura pracy fotoogniwa, T
- T_r – temperatura referencyjna ogniwa, K
- V_{oc} – napięcie ogniwa w stanie otwartym, V
- β_V – współczynnik temperaturowy napięcia otwartego, V/K
- T_{STC} – temperatura odniesienia w warunkach STC, K
- k – stała Boltzmana, $k = 1,38 \cdot 10^{-23}$, J/K
- q – ładunek elementarny, $q = 1,602 \cdot 10^{-19}$, C


W praktyce ogniwa słoneczne łączone są w konfiguracje szeregowo N_s (wzrost napięcia) i równoległe N_p (wzrost prądu) i wchodzi w skład jednego modułu. Zatem prąd jednego modułu fotowoltaicznego możemy wyrazić wzorem (5.4.):

$$I = N_p I_{ph} - N_p I_0 \left[\exp \left(\frac{q}{AkT} \left(\frac{U}{N_s} + \frac{I}{N_p} \cdot R_s \right) \right) - 1 \right] - \frac{\frac{N_p}{N_s} U + I R_s}{R_p} \quad (5.4)$$

gdzie:

- N_p – liczba ogniw połączonych równoległe
- N_s – liczba ogniw połączonych szeregowo

A obwód zastępczy panelu fotowoltaicznego przedstawiono na Rys. 5.4.




Rys.5.4. Schemat obwodu zastępczego panelu fotowoltaicznego

Implementacja modelu PV w MATLAB/Simulink

System fotowoltaiczny to grupa kilku szeregowo-równoległe połączonych ze sobą paneli/modułów fotowoltaicznych, których połączenie zapewnia odpowiedni (wymagany

np. przez falownik) poziom napięcia oraz prądu. System fotowoltaiczny został zamodelowany w środowisku MATLAB/Simulink, w sposób, jak pokazano na Rys.5.5.




Rys. 5.5. Widok modelu systemu fotowoltaicznego

Za implementację paneli fotowoltaicznych odpowiada blok PV Array z biblioteki Simscape Electrical wykorzystując równania (5.1-5.4). W zaproponowanym modelu uwzględniono dwie równoległe grupy modułów o łącznej mocy ok. 7 kWp (3,3 kWp i 3,6 kWp). Jako dane wejściowe należy zadać wartości natężenia promieniowania, temperaturę ogniw oraz parametry katalogowe paneli (w tym liczba ogniw szeregowych i równoległych). Na wyjściu bloku PV Array, jako wynik otrzymuje się wartość prądu i napięcia chwilowego.


System fotowoltaiczny został zintegrowany z następującymi przekształtnikami energoelektronicznymi:

- Przetwornica podwyższająca napięcie (ang. boost-up converter), którą podłączono do wyjścia modułów fotowoltaicznych (Rys. 5.6). Jest ona wykorzystywana do dostosowywania zmiennego napięcia z paneli do wymaganego, stałego poziomu napięcia na szynie prądu stałego falownika.




Rys. 5.6. Widok modelu przetwornicy podwyższającej napięcie

- Sterownik śledzenia punktu mocy maksymalnej MPPT (ang. Maximum Power Point Tracking), który jest niezbędny w celu realizacji algorytmu śledzenia punktu mocy maksymalnej (MPPT). W tym przypadku zaimplementowano algorytm P&O (ang. Perturb & Observe), którego schemat sterowania, bazujący na dyskretnym regulatorze proporcjonalno-całkującym PI, przedstawiono na Rys. 5.7[5].




Rys. 5.7. Zaimplementowane sterowanie przekształtnikiem podwyższającym napięcie

- Falownik napięcia, który jest ostatnim elementem składowym modelu i został zaimplementowany przy użyciu bloku Universal Bridge (Rys. 5.8).



Rys. 5.8. Universal Bridge

Falownik ten realizuje sterowanie wektorowe (DQ), do którego, wykorzystuje transformację Parka-Clarke'a. Pozwala to na niezależną regulację mocy czynnej (P) i biernej (Q) oddawanej do sieci. Implementację sterowania DQ pokazano na Rys. 5.9.



Rys. 5.9. Zaimplementowane sterowanie wektorowe falownikiem napięcia

5.2. System wiatrowy

Model matematyczny turbiny wiatrowej TW o osi poziomej

Moc mechaniczna, która jest generowana przez turbinę wiatrową o osi poziomej zależy od gęstości powietrza, promienia łopat oraz prędkości wiatru, co można opisać równaniem (5.5) [6]:


$$P_m = \frac{1}{2} \rho \pi R^2 v_w^3 C_p(\lambda, \beta) \quad (5.5.)$$

gdzie:

- | | |
|-----------------------|---|
| ρ | – gęstość powietrza (ok. 1,225 kg/m ³), kg/m ³ |
| R | – promień łopat turbiny wiatrowej, m |
| v_w | – Prędkość wiatru, m/s |
| $C_p(\lambda, \beta)$ | – współczynnik mocy turbiny |

W celu obliczenia mocy mechanicznej duże znaczenie ma wartość współczynnika C_p . Wartość współczynnika C_p jest nieliniową funkcją współczynnika szybkobieżności λ oraz kąta nastawienia łopat β . Współczynnik szybkobieżności λ definiowany jest jako stosunek prędkości liniowej końcówki łopat wirnika do prędkości wiatru, istnieje bezpośredni związek fizyczny pomiędzy prędkością obrotową turbiny a wartością współczynnika C_p , a w konsekwencji -

generowaną mocą mechaniczną przez turbinę. Zależność mocy turbiny wiatrowej od jej prędkości obrotowej dla $\beta = 0$ przedstawiono na Rys. 5.10.



Rys. 5.10. Charakterystyka turbiny wiatrowej dla $\beta = 0$, opracowanie własne na podstawie programu Matlab&Simulink

W modelu turbiny wiatrowej, w celu konwersji energii mechanicznej w energię elektryczną zaproponowano generator synchroniczny z magnesami trwałymi PMSG, który jest sprzężony wałem z turbiną wiatrową. Generator synchroniczny z magnesami trwałymi jest jednym z najczęstszych wyborów w przypadku stosowania go z turbiną wiatrową ze względu na wysoką sprawność, niezawodność oraz brak konieczności stosowania zewnętrznego obwodu wzbudzenia, co stanowczo upraszcza konstrukcję i eliminuje straty energii.

Model trójfazowego trapezoidalnego generatora synchronicznego z magnesami trwałymi opisują równania (5.6-5.8):

$$\frac{d}{dt}i_a = \frac{1}{3L_s}(2v_{ab} + v_{bc} - 3R_s i_a + \lambda p \omega_m (-2\phi'_a + \phi'_b + \phi'_c)) \quad (5.6.)$$

$$\frac{d}{dt}i_b = \frac{1}{3L_s}(-v_{ab} + v_{bc} - 3R_s i_b + \lambda p \omega_m (\phi'_a - 2\phi'_b + \phi'_c)) \quad (5.7.)$$

$$\frac{d}{dt}i_c = -\left(\frac{d}{dt}i_a + \frac{d}{dt}i_b\right) \quad (5.8.)$$

Gdzie:

L_s	–	Indukcyjność uzwojeń stojana, H
R_s	–	Rezystancja uzwojeń stojana, Ω
i_a, i_b, i_c	–	Prądy fazowe, A
$\phi'_a, \phi'_b, \phi'_c$	–	Siły elektromotoryczne faz a, b i c, w wartości względnej względem amplitudy strumienia λ , p.u.
v_{ab}, v_{bc}	–	Napięcia międzyfazowe, V
ω_m	–	Prędkość kątowna wirnika, rad/s
λ	–	Amplituda strumienia magnetycznego wytwarzanego przez magnesy trwałe wirnika w uzwojeniach stojana, Wb
p	–	Liczba par biegunów

Moment elektromagnetyczny generatora wyraża się wzorem (5.9):

$$M_e = p\lambda(\phi'_a i_a + \phi'_b i_b + \phi'_c i_c) \quad (5.9.)$$

Natomiast równanie ruchu mechanicznego turbiny opisuje wzór (5.10):


$$\frac{d}{dt} \omega_m = \frac{1}{J} (M_e - T_f - F \omega_m - T_m) \quad (5.10.)$$

Gdzie:

J	–	Moment bezwładności wirnika, $\text{kg} \cdot \text{m}^2$
M_e	–	Moment elektromagnetyczny, $\text{N} \cdot \text{m}$
T_f	–	Moment tarcia (mechanicznego), $\text{N} \cdot \text{m}$
F	–	Współczynnik tarcia lepkościowego, $\text{N} \cdot \text{m} \cdot \text{s} / \text{rad}$
ω_m	–	Prędkość kątowna wirnika, rad/s
T_m	–	Moment obciążenia mechanicznego, $\text{N} \cdot \text{m}$

Implementacja modelu turbiny wiatrowej TW w MATLAB/Simulink


Na potrzeby realizowanej pracy w środowisku Matlab&Simulink został opracowany model systemu wiatrowego - Rys. 5.7, który opracowano na podstawie równań 5.5-5.10.



Rys. 5.7. Widok modelu systemu wiatrowego

Przedstawiony na Rys. 5.7 model składa się z turbiny wiatrowej sprzężonej z prądnicą synchroniczną wyposażoną w magnesy trwałe. Wyjście prądnicy połączone z prostownikiem diodowym sprzężonym z przetwornicą podwyższającą napięcie i jednofazowym falownikiem napięcia.


Na Rys. 5.8. przedstawiono widok bloku modelu turbiny wiatrowej. Dane wejściowe do obliczeń momentu mechanicznego generowanego przez turbinę wiatrową to: prędkość obrotowa generatora, kąt nachylenia łopat wirnika i prędkość wiatru.



Rys. 5.8. Widok modelu turbiny wiatrowej

W symulacji, jako generator wykorzystano Blok Permanent Magnet Synchronous Machine, który implementuje trójfazową maszynę synchroniczną z magnesami trwałymi, zgodnie

z równaniami (5.5-5.10.) Uzwojenia stojana są połączone w gwiazdę z wewnętrznym punktem neutralnym. Okno dialogowe programu pokazano na Rys. 5.9.



Rys. 5.9. Okno dialogowe bloku *Permanent Magnet Synchronous Machine*

W dalszym kroku system turbiny wiatrowej został zintegrowany z przekształtnikami energoelektronicznymi analogicznie jak to opisano w przypadku systemu fotowoltaicznego.

5.3. System magazynowania energii

Model magazynu energii elektrycznej opiera się na rekurencyjnym równaniu różnicowym, które odwzorowuje przepływ energii elektrycznej w domenę dyskretną. Dynamikę stanu naładowania systemu magazynowania energii zamodelowano jako dyskretny

W celu zamodelowania magazynu przyjęto następujące założenia i ograniczenia:

- Stan naładowania baterii (ang. State of Charge) w chwili bieżącej t jest funkcją stanu z chwili poprzedniej $t-1$ oraz energii wymienionej z siecią w interwale Δt .
- Wartość naładowania magazynu (SoC) jest ograniczona do przedziału 0%-100%.
- Wartość ujemna energii oznacza ładowanie magazynu, a dodatnia jego rozładowanie.
- W modelu uwzględniono straty energii podczas konwersji, niezależnie dla procesu ładowania i rozładowania.
- Pominięto wpływ temperatury oraz efekt samorozładowania.

Wartość stanu naładowania SoC_t wyznaczana jest w oparciu o równanie:

$$SoC_t = SoC_{t-1} - \frac{\Delta E_t}{E_{max}} \quad (5.11)$$

Gdzie ΔE_t to efektywna zamiana energii w magazynie z uwzględnieniem strat konwersji wyrażona funkcją:

$$\Delta E_t = \begin{cases} \eta_{ch} E_{BESS_t} & \text{dla } E_{BESS_t} < 0 \text{ (ładowanie)} \\ \frac{E_{BESS_t}}{\eta_{dis}} & \text{dla } E_{BESS_t} > 0 \text{ (rozładowanie)} \\ 0 & \text{dla } E_{BESS_t} = 0 \text{ (spoczynek)} \end{cases} \quad (5.12)$$

Gdzie:

SoC_t – stan naładowania odpowiednio w kroku bieżącym i poprzednim, %

η_{ch} – sprawność procesu ładowania,

η_{dis} – sprawność procesu rozładowania,

E_{max} – pojemność znamionowa magazynu energii, kWh

E_{BESS_t} – energia pobrana lub oddana z magazynu energii w kroku t, kWh

Zaproponowany model magazynu energii ma charakter bilansowy. Jego struktura opiera się na dyskretnym bilansowaniu przepływów energii, co jest podejściem powszechnie stosowanym w algorytmach optymalizacji systemów zarządzania energią. Przyjęte uproszczenia, takie jak pominięcie wpływu temperatury, efektu pamięci czy samorozładowania, wynikają z założonego celu sterowania, którym jest optymalizacja ekonomiczna w horyzoncie dobowym, a nie szczegółowa analiza procesów elektrochemicznych. Taki model zapewnia optymalny kompromis pomiędzy dokładnością odwzorowania stanu naładowania (SoC) a złożonością obliczeniową.

Zaproponowane równania (5.11-5.12) uwzględniają nieliniowość strat w cyklu pracy magazynu energii. Podczas ładowania iloczyn $\eta_{ch} \cdot E_{BESS_t}$ zmniejsza wartość energii (straty cieplne), która jest ostatecznie przechowywana w magazynie. Podczas procesu rozładowywania iloraz E_{BESS_t} i η_{dis} wpływa na to, że wartość energii oddawanej do systemu jest mniejsza niż wartość energii pobrana z magazynu (straty cieplne).

W celu odwzorowania przez model fizycznego ograniczenia układu przekształtnikowego oraz elektrochemicznego ogniw zdefiniowano dodatkowe założenia:

- Ograniczenie mocy ładowania i rozładowania opisano za pomocą równania (5.13).

$$-P_{BESS,max\_charg} \cdot \Delta t \leq E_{BESS_t} \leq P_{BESS,max\_dis} \cdot \Delta t \quad (5.13)$$

- Ograniczenie stanu naładowania za pomocą równania (5.14).

$$SOC_{min} \leq SOC_t \leq SOC_{max} \quad (5.14)$$

Gdzie:

E_{BESS_t} – energia pobrana lub oddana z magazynu energii w kroku t , kWh

P_{BESS,max_charg} – maksymalna dopuszczalna moc ładowania, kW

P_{BESS,max_dis} – maksymalna dopuszczalna moc rozładowania, kW

Δt – długość kroku dyskretnego (np. 15 min),

SOC_t – stan naładowania odpowiednio w kroku bieżącym i poprzednim, %

SOC_{min} – minimalny dopuszczalny poziom naładowania magazynu energii, %

SOC_{max} – maksymalny dopuszczalny poziom naładowania magazynu energii, %

Z przedstawionych założeń wynika, że:

- energia wymieniana w pojedynczym kroku czasowym nie może przekroczyć wartości wynikających z mocy znamionowej przekształtnika oraz dopuszczalnych prądów baterii (równanie 5.13).
- Zmagazynowana energia nie może przekroczyć parametrów znamionowych pojemności magazynu (równanie (5.14)).

5.4. Model obciążenia lokalnego

Szczegółowe modele fizyczne instalacji fotowoltaicznej oraz turbiny wiatrowej opracowano w środowisku Simulink. Model obciążenia lokalnego został zaimplementowany jako zdeterminowany profil obciążenia, wyrażony poprzez zapotrzebowanie na moc czynną P_{LOAD_t} . Wartości zapotrzebowania na energię dla każdego kroku dyskretnego t są wprowadzane do modelu jako wektor danych wejściowych np. bazujący na rzeczywistych pomiarach z obiektu referencyjnego (co opisano szerzej w rozdziale 7).

5.5. Bilans mocy i współpraca z siecią elektroenergetyczną

W modelu sieć elektroenergetyczna pełni funkcje punktu bilansującego. Wymiana energii w punkcie przyłączenia do sieci jest realizowana poprzez chwilowe różnice między

łączną generacją źródeł OZE, a lokalnym zapotrzebowaniem i stanem pracy (ładowanie lub rozładowanie) magazynu energii. Do modelowania przyjęto, że dodatnia wartość P_{GRID_t} oznacza eksport do sieci zasilającej, a wartość ujemna oznacza pobór energii z sieci. Bilans mocy dla danego kroku t można opisać równaniem:

$$P_{GRID_t} = P_{PV_t} + P_{WT_t} + P_{BESS_t} - P_{LOAD_t} \quad (5.15.)$$

Gdzie:

P_{GRID_t} – moc wymieniana z siecią elektroenergetyczną, kW,

P_{PV_t} – moc generowana przez system fotowoltaiczny, kW,

P_{WT_t} – moc generowana przez system turbiny wiatrowej, kW,

P_{BESS_t} – moc magazynu energii, kW,

P_{LOAD_t} – moc zapotrzebowania lokalnego, kW,

6. SYMULACJA PRACY MODELU HYBRYDOWEGO SYSTEMU ZASILANIA TYPU SŁONECZNO-WIATROWEGO Z MAGAZYNEM ENERGII

W niniejszym rozdziale przedstawiono wyniki analizy przedstawiającej koszty eksploatacji proponowanego Hybrydowego Systemu Zasilania w zależności od pojemności magazynu energii oraz stanu jego naładowania na zakończenie okresu obliczeniowego (doby). Zbadano wpływ kluczowych parametrów wejściowych na całkowity zysk systemu oraz zweryfikowano korzyści wynikające z działania algorytmu optymalizacji w porównaniu do standardowego algorytmu regulowego.

6.1. Założenia do symulacji

Badania symulacyjne przeprowadzono dla modelu hybrydowego systemu zasilania typu solarno-wiatrowego opisanego w rozdziale 5, który składa się z:

- systemu fotowoltaicznego o mocy znamionowej ok. 7 kWp,
- systemu turbiny wiatrowej o mocy znamionowej 2 kW,
- systemu magazynowania energii złożonego z baterii litowo-jonowej o mocy znamionowej 3kW. Pojemność nominalna magazynu energii była zmienną – wg Tabeli 6.1.

Do przeprowadzenia badań przyjęto, że:


- Symulacje wykonano dla danych od dnia 1 stycznia 2025 r. do 31 grudnia 2025 r, które obejmują pełny rok kalendarzowy;
- optymalizację harmonogramu pracy magazynu energii ustawiono na 24 godziny (od godz. 00:00 do godz. 24:00) z rozdzielczością czasową 15 minut;
- Założono ograniczenia eksploatacyjne magazyny energii
 - minimalny stan naładowania magazynu to 10%,
 - maksymalny stan naładowania magazynu to 90%.
 - Sprawność cyklu magazynowania wynosi $\sim 90\%$, przy czym sprawność ładowania i rozładowania wynoszą $\eta_{ch} = \eta_{dis} = 95\%$
- Jednostkowy koszt degradacji magazynu energii przyjęto zgodnie z tabelą (6.1) i obliczono ze wzoru (4.9):

Tabela 6.1. Parametry techniczno-ekonomiczne analizowanych wariantów pojemnościowych magazynu energii


Lp.	Pojemność magazynu	Nakład inwestycyjny	Żywotność cykliczna, liczba cykli	Jednostkowy koszt degradacji
	kWh	PLN		PLN/kWh
1	5	20000	6000	0,3333
2	10	25000	6000	0,2083
3	15	30000	6000	0,1667

Do przeprowadzenia symulacji wykorzystano następujące rzeczywiste dane wejściowe:


- Dane meteorologiczne uzyskane z serwisu meteorologicznego dla lokalizacji Wrocław. Wykorzystano regionalny model numerycznej prognozy pogody ICON-D2 opracowany przez Deutscher Wetterdienst (DWD) - niemiecki narodowy serwis meteorologiczny [58]. Jest to model służący do wyznaczania krótkoterminowych prognoz pogody (do 48 godzin) w Europie Środkowej. Zbiór danych pogodowych obejmuje: temperaturę (Rys. 6.1), nasłonecznienie (Rys. 6.2) oraz prędkość wiatru (Rys. 6.3). W celu wyznaczenia teoretycznego maksimum efektywności ekonomicznej algorytmu, przyjęto założenie o doskonałej predykcji danych wejściowych. Oznacza to, że w momencie podejmowania decyzji algorytm dysponuje pełną wiedzą na temat przyszłych przebiegów generacji energii przez OZE.
- Dynamiczną cenę sprzedaży energii elektrycznej (Rys. 6.4) dla każdego okresu symulacji pozyskano z serwisu Polskich Sieci Elektroenergetycznych [59], powiększając wartości rynkowe o podatek VAT w wysokości 23% [66]. Przyjęto, że w przypadku występowania cen ujemnych, cena sprzedaży energii jest równa 0 PLN w danym okresie [66].
- Cenę zakupu energii elektrycznej ustalono na 1,10 zł/kWh na podstawie średniej ceny energii elektrycznej dla gospodarstw domowych [61].
- Profil obciążenia przyjęto na podstawie standardowych profili zużycia energii [18] skalowany na rok 2025. Dzielne zużycie energii ustalono na poziomie 10 kWh dla każdego dnia symulacji – Rys.6.5.




Rys.6.1 Temperatura otoczenia, opracowanie własne na podstawie [58]




Rys.6.2 Nasłonecznienie, opracowanie własne na podstawie [58]



Rys.6.3 Prędkość wiatru, opracowanie własne na podstawie [58]



Rys.6.4 Cena sprzedaży zakupu - Rynkowa cena energii elektrycznej (RCE) - 15 minutowe ceny energii elektrycznej, opracowanie własne na podstawie [59]



*Rys. 6.5. Profil obciążenia lokalnego w każdym dniu symulacji.
(opracowany na podstawie standardowych profili zużycia energii na 2025 rok), opracowanie własne na podstawie [18]*

6.2. Hybrydowy System Zasilania z algorytmem regułowym (RB) – wyniki symulacji i ich analiza


W celu obiektywnej oceny skuteczności działania autorskiego algorytmu optymalizacyjnego, przeprowadzono symulacje porównawcze stosując deterministyczny algorytm oparty na regułach (RB - Rule Based). Do obliczeń wykorzystując te same dane wyjściowe. Logika sterowania w algorytmie RB opiera się na bieżącym prostym bilansowaniu mocy. W przypadku występowania nadwyżek generacji z OZE (gdy produkcja OZE przewyższa zapotrzebowanie lokalne) następuje ładowanie magazynu energii, natomiast rozładowanie następuje w chwilach deficytu energii, aż do wyczerpania dostępnej pojemności.

Efektywność ekonomiczna


Do przeprowadzenia szczegółowej analizy charakterystyk energetycznych wybrano wariant z magazynem energii o pojemności 15 kWh. Całoroczną charakterystykę pracy HSZ przedstawiono na Rys. 6.6. Wykresy prezentują miesięczny bilans energetyczny (a), zestawienie generacji i zużycia (b), bilans finansowy (c) oraz ilość energii wymienianej z magazynem (d) – z podziałem na ładowanie i rozładowanie. W celu przeprowadzenia analizy dynamiki pracy w skrajnych warunkach pogodowych, zestawiono wyniki dobowe dla dwóch charakterystycznych okresów - lipca (Rys. 6.7.) oraz lutego (Rys. 6.8.).

Analiza otrzymanych wyników pokazuje zależność efektywności sterowania regułowego od sezonowości. Miesiące wiosenno-letnie (od marca do października) charakteryzują się wysoką generacją energii z OZE, znacząco przekraczającą zapotrzebowanie własne HSZ (Rys. 6.6.b). Jak wynika z Rys. 6.7 dla lipca, w okresie letnim występują regularne, wysokie nadwyżki wytwarzania, które algorytm RB efektywnie wykorzystuje do cyklicznego ładowania magazynu. Pozwala to na pokrycie zapotrzebowania wieczornego i nocnego, co w przypadku dużego magazynu (15 kWh) prowadzi do znaczącego ograniczenia konieczności zakupu energii z sieci, a w dniach o wysokim nasłonecznieniu nawet do pełnej samowystarczalności.


Zupełnie odmienną charakterystykę pracy odnotowano w miesiącach jesienno-zimowych (listopad-luty). W tym okresie generacja energii z OZE jest minimalna i zazwyczaj nie pokrywa bieżącego zapotrzebowania, co obrazuje bilans na Rys. 6.8 - luty. Ponieważ algorytm RB uzależnia ładowanie magazynu wyłącznie od wystąpienia nadwyżek mocy, stąd w miesiącach zimowych pozostaje bezczynny. Jak widać na Rys. 6.8.d, wymiana energii pomiędzy HSZ, a magazynem jest bliska zeru dla większości dni. Z przeprowadzonej analizy wynika, że przy zastosowaniu prostego sterowania regułowego RB cała dostępna energia z OZE jest zużywana na bieżąco. Brak nadwyżek energii uniemożliwia ładowanie magazynu, czyniąc go w okresie zimowym niemal bezużytecznym.



Rys. 6.6. Miesięczne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie RB) : a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 6.7. Dienne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie RB) - lipiec: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 6.8. Dzielne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie RB) - luty: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,

Analiza wrażliwości

Przeprowadzono również symulacje dla pojemności magazynu energii równej 5 kWh oraz 10 kWh, a zestawienie kluczowych wskaźników techniczno-ekonomicznych zaprezentowano w tabeli 6.2.

Tabela 6.2 Wyniki analizy techniczno-ekonomicznej pracy algorytmu regulowego w zależności od pojemności magazynu energii

Pojemność magazynu	Wynik finansowy systemu bez magazynu energii	Wynik finansowy systemu ¹⁾	Koszt degradacji magazynu	Zysk ²⁾	Liczba pełnych cykli	Zysk na jeden cykl	Okres zwrotu	Wskaźnik autokonsumpcji
kWh	PLN	PLN	PLN	PLN	-	PLN	lata	%
5	-815	-81	767	734	460	1,60	27,3	39,3
10		92	580	907	278	3,26	27,6	42,6
15		116	477	931	191	4,88	32,2	43,2

¹⁾Rzeczywiste wyniki finansowe, uwzględniający całkowity zysk lub koszt (dla wyniku ujemnego) działania systemu HSZ z uwzględnieniem realnych przepływów energii bez kosztów degradacji baterii w analizowanym okresie.

²⁾Liczony jako różnica wyniku finansowego systemu z magazynem energii i wyniku finansowego systemu bez magazynu energii.

Analiza otrzymanych wyników (tabela 6.2) jednoznacznie wykazuje ograniczenie skalowalności metody sterowania RB. Dowodzi tego fakt, że trzykrotny wzrost pojemności magazynu (200%) z 5 kWh do 15 kWh, zwiększa zysk z 734 PLN do 931 PLN, czyli o zaledwie 27%. Z Tabeli 6.2 wynika również, że w analizowanym przypadku wraz ze wzrostem pojemności magazynu maleje liczba cykli jego pracy z 460 dla pojemności 5 kWh do 191 cykli dla 15 kWh. Wzrost wskaźnika autokonsumpcji jest również marginalny, ponieważ zmienia się z 39,3% do zaledwie 43,2%. Na tej podstawie można stwierdzić, że przy danym profilu generacji z OZE oraz profilu obciążenia lokalnego, dalsze zwiększanie pojemności magazynu bez zmiany sposobu sterowania nie przynosi dalszych wymiernych korzyści.

Jest to związane z tym, że algorytm RB nie uwzględnia w swoim działaniu prognoz pogody, ani harmonogramów działania odbiorników lokalnych. Magazyn o dużej pojemności (15 kWh) przez większość czasu pozostaje nieużywany - o czym świadczy stosunkowo mała liczba cykli pracy. Algorytm RB nie podejmuje decyzji o celowym arbitrażu (ładowanie lub rozładowanie). Skutkiem tego jest wydłużenie prostego okresu zwrotu z 27 lat dla magazynu o pojemność 5 kWh do 32 lat dla 15 kWh.

Wynika z tego, że sterowanie regułowe przynosi wymierne korzyści jedynie w przypadku magazynów energii o pojemności mniejszej lub równej dziennemu zapotrzebowaniu systemu na energię. Natomiast inwestycja w proste sterowanie i duży magazyn energii, którego pojemność przewyższa dzienne zapotrzebowanie odbiorników lokalnych, staje się nie opłacalne. Uzyskane wyniki stanowią uzasadnienie do wdrożenia zaawansowanych metod optymalizacji, których celem będzie większa intensyfikacja cykli pracy magazynu w celu maksymalizacji korzyści finansowych.

6.3. Hybrydowy System Zasilania z algorytmem genetycznym (GA) – wyniki symulacji komputerowej


W kolejnym podrozdziale przeprowadzono badania autorskiego algorytmu optymalizacji, którego zadaniem jest harmonogramowanie pracy magazynu energii wykorzystując m.in. dobowe rynkowe zmiany cen energii sprzedaży, profil generacji energii z OZE oraz harmonogram pracy odbiorników lokalnych. Głównym zadaniem działania algorytmu jest maksymalizacja autokonsumpcji systemu HSZ poprzez magazynowanie nadwyżek energii z OZE w okresach szczytowego wytwarzania oraz realizacja sprzedaży energii zmagazynowanej do sieci elektroenergetycznej w godzinach szczytowego zapotrzebowania, gdy dobowe ceny energii osiągają największe wartości.

Efektywność ekonomiczna


Przeprowadzono symulacje pracy systemu wyposażonego w magazyn o pojemności 15 kWh, który sterowano zaproponowanym autorskim algorytmem optymalizacji (GA). Otrzymane wyniki zaprezentowano w postaci wykresów w perspektywie rocznej i miesięcznej. Roczny bilans energetyczny i finansowy dla każdego miesiąca przedstawiono na Rys. 6.9. Dobowe wyniki dla reprezentatywnych dni lipca (okres letni) zilustrowano na Rys. 6.10. Dobowe wyniki dla reprezentatywnych dni lutego (okres zimowy) przedstawiono na Rys. 6.11.

Z analizy otrzymanych wyników symulacji wynika, że w miesiącach wiosenno-letnich (marzec-październik), charakteryzujących się wysoką generacją energii z OZE (Rys. 6.9.b), algorytm GA dąży do wzrostu autokonsumpcji do maksymalnego poziomu. Jednak analiza przebiegów dobowych dla lipca (Rys. 6.10.) wskazuje na istotną różnicę, ponieważ algorytm nie ogranicza się do pasywnego magazynowania nadwyżek, a wykonuje arbitraż cenowy. Na rysunku 6.10.d widoczna jest intensywna praca magazynu. System celowo steruje momentem rozładowania, przesuwając oddawanie energii na godziny wieczornego szczytu cenowego, co pozwala zmaksymalizować przychód widoczny na bilansie finansowym (Rys. 6.10.c).


Najbardziej znacząca przewaga algorytmu predykcyjnego uwidacznia się jednak w miesiącach zimowych. W przeciwieństwie do algorytmu RB, który w okresie niedoboru generacji z OZE pozostawiał magazyn w stanie bezczynności, algorytm GA utrzymuje jego aktywność przez cały rok. Analiza wyników z lutego (Rys. 6.11) dowodzi, że mimo śladowej generacji energii z OZE, magazyn realizuje cykle ładowania i rozładowania (Rys. 6.11.d). Jest to wynik działania mechanizmu arbitrażu cenowego. Algorytm, wykorzystując 24-godzinną predykcję generacji energii z OZE, informację o dynamicznych cenach energii (RCE) oraz znany profil obciążenia i na tej podstawie identyfikuje okresy najniższych cen (np. dolina nocna lub południowa). Następnie zgromadzona energia zostaje sprzedana po najwyższej wycenie rynkowej dla danego dnia. Dzięki takiemu podejściu, system GA generuje dodatnie przepływy pieniężne (lub minimalizuje straty) nawet w dniach, w których wytwarzanie energii z OZE jest bliskie zeru (Rys. 6.11.c).



Rys. 6.9. Miesięczne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie GA): a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 6.10. Dienne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie GA) - lipiec: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 6.11. Dzielne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie GA) - luty: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,


Analiza mechanizmu działania

W celu wyjaśnienia zarówno działania, jak i przewagi autorskiego algorytmu optymalizacji nad sterowaniem regułowym, przeprowadzono szczegółową analizę przebiegów czasowych wybranego reprezentatywnego dnia. Na Rys. 6.12 pokazano przebiegi generacji energii z OZE, profilu obciążenia, 15-minutowe dynamiczne ceny sprzedaży energii oraz wynikowy harmonogram pracy magazynu wyznaczony przez algorytm GA dla wybranej doby letniej (3 lipca 2025). Szczegółowa analiza zależności między tymi wykresami umożliwia weryfikację mechanizmu arbitrażu cenowego przeprowadzanego przez algorytm GA.

Profil cen energii (RCE) w dniu 3 lipca 2025 charakteryzuje się dużą zmiennością dobową (Rys. 6.12). Na Rys. 6.12.a widoczna jest "dolina cenowa" w godzinach południowych (godziny 09:00-15:00) wynikająca z nadpodaży generacji z OZE w krajowym systemie energetycznym. Na rysunku tym również widoczny jest "szczyt wieczorny" (godziny 18:00-21:00), kiedy ceny sprzedaży energii osiągają maksimum dobowe. Jednocześnie analizując wykres (Rys. 6.12.b) można zaobserwować, że w godzinach południowych występuje szczyt generacji lokalnej z instalacji OZE, znacznie przekraczający zapotrzebowanie własne HSZ. Autorski algorytm, optymalizacji rozpatruje te dane i doskonale wykorzystuje te uwarunkowania do przeprowadzenia arbitrażu cenowego.

Analiza Rys. 6.12.c pozwala dostrzec, że w godzinach porannych (00:00 do 06:00) magazyn wykorzystuje zgromadzoną energię z poprzedniego dnia, aby zaspokoić zapotrzebowanie na energię przez obciążenie lokalne. Następnie w kolejnej fazie (09:00-15:00), w której ceny energii na rynku są najniższe, następuje intensywne ładowanie magazynu z użyciem energii wytwarzanej przez lokalne źródła OZE. W tym czasie stan naładowania magazynu (SoC) gwałtownie rośnie z poziomu 10% do 90% (Rys. 6.12.d).

Po osiągnięciu pełnego stanu naładowania, algorytm wstrzymuje się z rozładowaniem (15:00-18:00) w oczekiwaniu na wzrost przyszłych cen - „szczyt wieczorny”. W momencie wystąpienia na rynku szczytu cenowego, następuje gwałtowne rozładowywanie magazynu i spadek stanu naładowania magazynu (SoC) z 90% do wymaganego poziomu 30% na koniec dnia. Analiza przebiegów czasowych (Rys.6.12) pracy autorskiego algorytmu optymalizacji dowodzi, że algorytm nie traktuje magazynu jedynie jako bufora na potrzeby własne, ale aktywnie dostosowuje harmonogram pracy magazynu do dynamicznych cen energii. Energia jest aktywnie eksportowana do sieci, co pozwala na wzrost zysku finansowego niemożliwego do uzyskania za pomocą sterowania regułowego.



Rys. 6.12. Przebiegi dobowe wielkości energetycznych uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 15 kWh (sterowanie GA) - 3 lipca: a) Dynamiczne 15-minutowe ceny energii (RCE), b) Generacja energii z OZE wraz z zużyciem energii, c) Moc wymiany energii przez magazyn (dodatnia - rozładowanie, ujemna - ładowanie), d) Przebieg stanu naładowania magazynu energii,

Analiza wrażliwości na pojemność i SoC na koniec dnia

Implementacja predykcyjnego algorytmu genetycznego znacząco zmienia charakterystykę pracy HSZ, co szczegółowo przeanalizowano w tym podrozdziale. Algorytm GA, wykorzystuje predykcję generacji z OZE (na potrzeby symulacji w tym rozdziale przyjęto założenie o prognozie doskonałej), harmonogramu obciążenia oraz cen energii elektrycznej i na tej podstawie podejmuje decyzję o sterowaniu magazynem energii w oparciu o kryterium maksymalizacji zysku (równanie 4.1) z uwzględnieniem kosztów degradacji magazynu energii oraz sprawności procesów konwersji energii. Wyniki dla zmiennych pojemność magazynu oraz różnych wymaganych stanów naładowania magazynu energii na koniec dnia SoC_{end} przedstawiono w tabeli 6.3.

Tabela 6.3. Wpływ parametru docelowego stanu naładowania SoC_{end} na wskaźniki techniczno-ekonomiczne pracy systemu HSZ

Wariant SoC	Pojemność magazynu	Wynik finansowy systemu ¹⁾	Koszt degradacji magazynu	Zysk ²⁾	Poprawa względem RB,	Liczba cykli pełnych	Zysk na jeden cykl	Okres zwrotu	Wskaźnik autokonsumpcji
%	kWh	PLN	PLN	PLN	%	-	PLN	lata	%
10	5	-139	762	676	-7,86	457	1,48	29,6	35,7
30		-149	793	666	-9,26	476	1,40	30,0	35,9
50		-178	911	637	-13,17	547	1,16	31,4	34,8
70		-273	984	542	-26,11	590	0,92	36,9	30,5
90		-472	1190	343	-53,24	714	0,48	58,3	25,4
10	10	235	1032	1050	15,74	495	2,12	23,8	30,4
30		421	932	1236	36,29	477	2,59	20,2	35,2
50		338	932	1153	27,18	447	2,58	21,7	37,0
70		-103	838	712	-21,51	402	1,77	35,1	31,8
90		-345	1167	470	-48,19	560	0,84	53,2	20,0
10	15	624	1005	1438	54,50	402	3,58	20,9	30,4
30		799	1046	1614	73,32	418	3,86	18,6	34,3
50		659	1022	1473	58,26	613	2,40	20,4	34,3
70		129	735	943	1,33	294	3,21	31,8	34,3
90		-252	1042	563	-39,51	417	1,35	53,3	19,0

¹⁾Rzeczywisty wynik finansowy, uwzględniający całkowity zysk lub koszt (dla wyniku ujemnego) działania systemu HSZ z uwzględnieniem realnych przepływów energii bez kosztów degradacji baterii w analizowanym okresie.


²⁾Liczony jako różnica wyniku finansowego systemu z magazynem energii i wyniku finansowego systemu bez magazynu energii.

Z analizy Rys. 6.13 wynika, że istnieje zależność między pojemnością magazynu energii a opłacalnością stosowania zaawansowanych metod sterowania wykorzystujących GA. Na wykresie można wyodrębnić dwa obszary. Dla magazynu o małej pojemności (5 kWh), wynoszącym w analizowanym przypadku 50% dobowego zużycia energii, zaproponowany algorytm GA odnotował spadek zysku względem referencyjnego algorytmu RB dla każdego z badanych scenariuszy SoC_{end} (od -7,86% do 53,24%). Przyczyną takiego stanu rzeczy jest zbyt mała pojemność magazynu, przez co obszar decyzyjny algorytmu jest minimalny. W takim scenariuszu przez większość czasu magazyn ładuje się i rozładowuje cyklicznie, co wymuszone jest poprzez bilans mocy w systemie (generacja z OZE i zapotrzebowanie lokalne). Algorytm GA biorąc pod uwagę koszty degradacji magazynu (zgodnie z funkcją celu - równanie 4.1), często rezygnował z nisko opłacalnych operacji, które były realizowane przez algorytm RB.


Przewaga zaproponowanego algorytmu genetycznego uwidacznia się dopiero przy wzroście pojemności magazynu energii. Dla magazynu o pojemności 15 kWh, w przypadku wariantu optymalnego, w którym $SoC_{end} = 30\%$, przepływy pieniężne wzrosły aż o 73,32% względem sterowania RB. Jest to wynikiem inteligentnego sterowania przez GA, gdzie algorytm efektywniej zagospodarował większą pojemność magazynu energii i agresywniej realizował arbitraż cenowy, co ostatecznie pozwoliło skrócić okres zwrotu z 32 lat dla RB do 19 lat dla GA (Rys. 6.14).

Przeprowadzone symulacje dla różnych parametrów SoC_{end} (wymagany stan naładowania magazynu na koniec doby) i analiza wyników (tabela 6.3. i Rys. 6.15) pozwoliły na wyznaczenie optymalnych ustawień algorytmu GA. Najwyższą efektywność ekonomiczną uzyskano przy parametrze $SoC_{end} = 30\%$, która osiągnęła odpowiednio 1614 PLN dla magazynu o pojemności 15 kWh i 1236 PLN dla magazynu 10 kWh. Analizy wykazały, że poziom ten stanowi pewnego rodzaju kompromis. Taki warunek pozwala na głębokie rozładowanie magazynu podczas wieczornego szczytu cenowego, ale jednocześnie zachowanie rezerw na poranne zaspokojenie zapotrzebowania przez obciążenie lokalne. Ten scenariusz pozwala unikać zakupu energii z sieci elektroenergetycznej po niekorzystnej cenie, gdy nie ma generacji energii ze źródeł OZE lub jest marginalna. W przypadku parametru $SoC_{end} = 10\%$, zysk systemu jest niższy niż dla wariantu 30%. Dla zbyt niskiego stanu naładowania magazynu algorytm często jest zmuszony do sprzedaży energii elektrycznej w okresach o niższej cenie, tylko po to, aby spełnić warunek końcowy wymagany stanem naładowania SoC_{end} . Natomiast dla parametru $SoC_{end} = 90\%$ utrzymanie wysokiego stanu naładowania magazynu na koniec dnia powoduje spadek zysku systemu o ok. 50% względem optimum. Wysoki SoC_{end} uniemożliwia pełne wykorzystanie energii z OZE, przez co nie możliwy staje się arbitraż cenowy. Dodatkowo


wariant ten posiada najmniejszy wskaźnik autokonsumpcji wynoszący 19% dla magazynu o pojemności 15 kWh.



Rys. 6.13. Analiza wrażliwości wskaźnika względnej poprawy zysku algorytmu genetycznego (GA) względem sterowania regulowego (RB) w zależności od pojemności magazynu energii oraz zadanego stanu końcowego SoC_{end}



Rys. 6.14. Zależność okresu zwrotu nakładów inwestycyjnych w zależności od pojemności magazynu energii oraz zadanego stanu końcowego SoC_{end}



Rys. 6.15. Wpływ zadanego stanu końcowego naładowania SoC_{end} na roczny zysk dla wyniku finansowego systemu względem systemu bez magazynu energii dla wybranych wariantów pojemności magazynu energii.

7. SYMULACJA PRACY HYBRYDOWEGO SYSTEMU ZASILANIA TYPU SŁONECZNO-WIATROWEGO Z MAGAZYNEM ENERGII Z WYKORZYSTANIEM RZECZYWISTYCH DANYCH POMIAROWYCH

W rozdziale przedstawiono analizę pracy hybrydowego systemu zasilania typu solarno-wiatrowego, zintegrowanego z magazynem energii elektrycznej. Celem symulacji była ocena korzyści finansowych z wdrożenia magazynu energii oraz efektywności działania systemu w rzeczywistych warunkach eksploatacyjnych, ze szczególnym uwzględnieniem weryfikacji skuteczności działania zaproponowanego algorytmu optymalizacji harmonogramu pracy magazynu energii.

Symulacje przeprowadzono wykorzystując rzeczywiste dane pomiarowe wytwarzania energii elektrycznej przez instalację fotowoltaiczną i turbinę wiatrową zarejestrowane na wybranym obiekcie. Takie podejście pozwoliło na dokładne odwzorowanie zmieniających się warunków pracy systemu, a przede wszystkim ocenę jego zachowania w kontekście zmienności źródeł odnawialnych.

7.1. Hybrydowy system zasilania

Badany hybrydowy system zasilania zlokalizowany jest w miejscowości Kaźmierz k. Poznania. W jego skład wchodzi 3 instalacje fotowoltaiczne (Rys.7.1. i Rys.7.2.) o łącznej mocy 17 kWp składające się z [60]:

- Inwertera SolarLake 7000 TL-PM 3F wraz 12 panelami 250Wp i 11 panelami 275Wp;
- Dwóch inweterów PowerOne Aurora 4200 W wraz z 20 panelami 275Wp;
- Inwenter Sofar 5.5 KTL-X 5000W wraz z 16 panelami 340Wp;



Rys. 7.1. Instalacja fotowoltaiczna wchodzącą w skład hybrydowego systemu zasilania [60]



Rys. 7.2. Instalacja fotowoltaiczna wchodzącą w skład hybrydowego systemu zasilania [60]

Kolejnym elementem systemu zasilania jest system turbiny wiatrowej, składający się z dwóch turbin wiatrowych o mocy znamionowej 2000 W każda. Parametry turbiny to: średnica wirnika to ok. 1,7 m, minimalna prędkość wiatru 3 m/s, natomiast znamionowa prędkość wiatru wynosi 13 m/s. Turbiny zostały zainstalowane na masztach umieszczonych na dachu budynku - Rys. 7.3.



Rys. 7.3. Instalacja turbin wiatrowych wchodzących w skład hybrydowego systemu zasilania [60]

W trakcie pracy systemu rejestrowano zużycie energii elektrycznej w badanym obiekcie. Głównym źródłem zapotrzebowania na energię było ogrzewanie oparte o promienniki podczerwieni, które charakteryzowało się cykliczną pracą i zmiennym obciążeniem w zależności od warunków pogodowych. Największe zużycie przypadało na miesiące zimowe. Zarejestrowane dane zużycia energii stanowiły podstawę do oceny bilansu energetycznego i ekonomicznego systemu, ze szczególnym uwzględnieniem skuteczności zastosowanego algorytmu harmonogramowania pracy magazynu energii.

7.2. Założenia do symulacji

Badania symulacyjne przeprowadzono dla modelu hybrydowego systemu zasilania typu solarno-wiatrowego, który opisano w podrozdziale 7.1. Konfiguracja sprzętowa układu obejmuje:

- system fotowoltaiczny o mocy znamionowej ok. 17 kWp,
- system turbin wiatrowych o mocy znamionowej 4 kW,
- lokalny system odbiorników lokalnych o łącznym zapotrzebowaniu na energię elektryczną na poziomie ok. 18 000 kWh.

Na potrzeby przeprowadzenia badań przyjęto następujące założenia i wytyczne:

- System HSZ wyposażono w litowo-jonowy zasobnik o mocy znamionowej falownika 10 kW. Jako pojemność nominalną magazynu energii przyjęto 50 kWh. Koszt zakupu systemu magazynowania przyjęto 65 000 PLN.


- Symulacje przeprowadzono dla pełnego roku kalendarzowego, dla danych obejmujących okres od dnia 1 stycznia 2025 r. do 31 grudnia 2025 r.,
- optymalizację harmonogramu pracy magazynu energii ustawiono na 24 godziny (od godz. 00:00 do godz. 24:00) z rozdzielczością czasową 15 minut,
- Założono ograniczenia eksploatacyjne magazynu energii:
 - minimalny stan naładowania magazynu na 10%,
 - maksymalny stan naładowania magazynu na 90%.
 - Sprawność cyklu magazynowania wynosi $\sim 90\%$, przy czym sprawność ładowania i rozładowania są symetryczne i wynoszą $\eta_{ch} = \eta_{dis} = 95\%$
- Jednostkowy koszt degradacji magazynu energii i obliczono ze wzoru (4.9) i wynosi on 0,1083 PLN/kWh.

Do przeprowadzenia symulacji wykorzystano następujące rzeczywiste dane wejściowe:


- Prognozy natężenia promieniowania słonecznego, temperatury oraz prędkości wiatru (dostępne z wyprzedzeniem 1-dniowym) dla lokalizacji Kaźmierz. Dane uzyskano z regionalnego modelu numerycznego prognoz pogody ICON-D2 [58],
- dynamiczną cenę rynkowej energii elektrycznej (RCE) dla każdego okresu symulacji pozyskano z serwisu Polskich Sieci Elektroenergetycznych [59], powiększając wartości rynkowe o podatek VAT w wysokości 23% [66]. Przyjęto, że w przypadku występowania cen ujemnych, cena sprzedaży energii jest równa 0 PLN w danym okresie [66]. Przebieg zmienności cen przedstawiono na Rys. 7.4.,
- cenę zakupu energii elektrycznej ustalono na 1,10 zł/kWh na podstawie średniej ceny energii elektrycznej dla gospodarstw domowych [61],
- wykorzystano rzeczywisty profil generacji systemu fotowoltaicznego oraz turbiny wiatrowej - Rys. 7.5,
- wykorzystano rzeczywisty profil obciążenia zarejestrowanego na obiekcie (Rys.7.6). Średnie dzienne zużycie energii analizowanego obiektu wynosi ok. 50 kWh.

W zgromadzonych danych pomiarowych wystąpiły nieliczne (kilka dni) przerwy w ich rejestracji, wynikające z m.in. przerw technologicznych. W celu przeprowadzenia ciągłej symulacji dla całego roku, brakujące wartości zostały uzupełnione. Dla generacji z OZE w miejscach braków wykorzystano wartości wyliczone przez opracowany model predykcyjny. Pozwoliło to odtworzyć wytwarzanie energii adekwatną do warunków pogodowych w danym dniu. Natomiast założono, że profil zużycia energii jest powtarzalny dzień do dnia (podobne


zachowania domowników). Dlatego brakujące dane uzupełniono, kopiując wartości z dnia poprzedniego.




Rys.7.4 Cena sprzedaży energii – na podstawie Rynkowej ceny energii elektrycznej (RCE) - 15 minutowe ceny energii elektrycznej, opracowanie własne na podstawie [59]



Rys.7.5 Profil generacji systemu fotowoltaicznego, opracowanie własne na podstawie [60]



Rys. 7.6 Profil generacji systemu wiatrowego, opracowanie własne na podstawie [60]




Rys. 7.7. Profil obciążenia lokalnego, opracowanie własne na podstawie [60]

7.3. Prognozowanie generacji ze źródeł OZE


Efektywność algorytmów harmonogramowania pracy magazynów energii w mikrosieciach jest ściśle skorelowana z jakością danych wejściowych. Aby odwzorować

generację źródeł OZE, w pracy wykorzystano sztuczne sieci neuronowe typu LSTM. Sieci te z powodzeniem wykorzystywane są do analizy szeregów czasowych, ponieważ pozwalają na wykrywanie długoterminowych zależności w danych meteorologicznych. Jest to ważne dla dokładności predykcji prognozy wytwarzania energii przez OZE w horyzoncie dnia następnego.

Sieci trenowano na jednodniowych prognozach pogodowych (natężenie promieniowania słonecznego, temperatura otoczenia, prędkość wiatru) oraz historycznych danych generacji z obiektu rzeczywistego w okres 6 miesięcy (01.07.2024 r. do 31.12.2024 r.). Dane uczące dla instalacji fotowoltaicznej oraz instalacji turbiny wiatrowej przedstawiono na Rys. 7.8. i Rys. 7.9.



Rys. 7.8. Dane zbioru uczącego dla instalacji fotowoltaicznych - korelacja mocy wyjściowej z natężeniem promieniowania słonecznego (dane zebrane od 1.07.2024 r. do 31.12.2024 r.).



Rys. 7.9. Dane zbioru uczącego dla instalacji turbin wiatrowych - korelacja mocy wyjściowej z prędkością wiatru (dane zebrane od 1.07.2024 r. do 31.12.2024 r.).

Na Rys. 7.10. przedstawiono ocenę skuteczności predykcji modelu sieci neuronowej LSTM dla systemu fotowoltaicznego w formie wykresu punktowego. Analizę statyczną modelu wykonano na danych testowych obejmujący cały rok kalendarzowy od 01.01.2025 r. do 31.12.2025 r. Oś X prezentuje dane pomiarowe z obiektu rzeczywistego, natomiast oś Y stanowią wartości wyjściowe z modelu predykcji. Uzyskano wysoki współczynnik determinacji $R^2=0,849$, co jednoznacznie potwierdza zdolności modelu do odwzorowywania dynamiki zmian nasłonecznienia. Histogram rozkładu błędów predykcji (Rys. 7.11.) przedstawia charakterystykę zbliżoną do rozkładu normalnego z wyraźnie zaznaczoną dominantą w zerze. Ilościowe wskaźniki błędów dla zbioru testowego wyniosły odpowiednio:


- MAE (Średni błąd bezwzględny): 0,510 kW
- RMSE (Błąd średniokwadratowy): 1,033 kW

Na Rys. 7.12. przedstawiono ocenę skuteczności predykcji modelu sieci neuronowej LSTM dla systemu turbiny wiatrowej w formie wykresu punktowego. Także dla tego modelu analizę statyczną wykonano na danych testowych obejmujący cały rok kalendarzowy od 01.01.2025 r. do 31.12.2025 r. Oś X prezentuje dane pomiarowe z obiektu rzeczywistego, natomiast oś Y stanowią wartości wyjściowe z modelu predykcji. Wykres pokazuje zdolność sieci


neuronowej do nauczenia się fizycznej krzywej mocy turbiny. Jednak widoczna jest strefa nieczułości poniżej prędkości startowej (~ ok. 3 m/s), gdzie generacja energii jest bliska zeru. Dla wyższych prędkości model dostatecznie odwzorowuje nieliniową charakterystykę mocy turbiny. Specyfika badanego okresu, w którym dominowały niskie prędkości wiatru znacząco wpłynęła na uzyskanie umiarkowanego współczynnika determinacji ($R^2=0,483$). Mimo trudnych warunków pracy i zdominowanie zbioru danych przez niskie prędkości wiatru, uzyskano bardzo niskie wartości błędów bezwzględnych:

- MAE (Średni błąd bezwzględny): 0,0038 kW
- RMSE (Błąd średniokwadratowy): 0,0083 kW


Należy podkreślić, że uzyskana niska wartość współczynnika determinacji ($R^2=0,483$) jest wynikiem niskiego poziomu wytwarzania energii przez turbinę wiatrową. W badanym okresie turbina wiatrowa pracowała głównie w zakresie szumów i mocy minimalnych, stąd wariancja sygnału użytecznego była niewielka. W takich warunkach wskaźniki błędu bezwzględnego (MAE, RMSE) są bardziej miarodajną oceną jakości predykcji niż wskaźnik korelacji, potwierdzając, że model nie generuje fałszywych prognoz w okresach bezwietrznych.




Rys. 7.10. Korelacja predykcji z danymi pomiarowymi mocy instalacji fotowoltaicznej



Rys. 7.11. Histogram rozkładu błędów predykcji mocy instalacji fotowoltaicznej



Rys. 7.12. Korelacja predykcji z danymi pomiarowymi mocy instalacji turbiny wiatrowej




Rys. 7.13. Histogram rozkładu błędów predykcji mocy instalacji turbiny wiatrowej


Aby potwierdzić poprawność odwzorowywania charakterystyk rzeczywistych obiektów przez sieć neuronową, przeprowadzono analizę porównawczą za pomocą zbioru testowego. Na Rys. 7.14. przedstawiono zestawienie prognozowanej mocy systemu fotowoltaicznego (punkty w kolorze czerwonym) z rzeczywistymi danymi pomiarowymi (punkty w kolorze niebieskim) w funkcji prognozowanego natężenia promieniowania słonecznego. Otrzymane wykresy potwierdzają prawidłową pracę modelu sieci - wzrost natężenia promieniowania słonecznego powoduje proporcjonalny wzrost generowanej mocy wyjściowej. Punkty w kolorze czerwonym (model predykcji) tworzą zwarty trend "środkowy", podczas gdy dane rzeczywiste (punkty w kolorze niebieskim) cechują się większym rozrzutem, który wynika z czynników losowych (np. częściowe lokalne zachmurzenie), które są filtrowane przez model LSTM. Przebiegi czasowe z rozdzielczością 15-minutową w całym okresie symulacji (365 dni) zaprezentowano na Rys. 7.16. Szczegółowe przebiegi czasowe z rozdzielczością 15-minutową w wybranych dniach zaprezentowano na Rys. 7.18.

Analogiczną analizę wykonano dla systemu turbiny wiatrowej i przedstawiono na Rys. 7.15. Pokazuje on zależność generowanej mocy systemu wiatrowego od prognozowanej prędkości wiatru. Zarówno dane pomiarowe (punkty w kolorze niebieskim), jak i wyjście modelu (punkty w kolorze czerwonym) ujawniają typową, nieliniową charakterystykę turbiny.


Wyraźnie widoczna jest strefa nieczułości dla niskich prędkości wiatru. Powyżej prędkości startowej (>3 m/s) następuje wykładniczy wzrost mocy. Przebiegi czasowe z rozdzielczością 15-minutową w całym okresie prowadzenia symulacji (365 dni) zaprezentowano na Rys. 7.17. Szczegółowe przebiegi czasowe z rozdzielczością 15-minutową dla wybranych dni zaprezentowano na Rys. 7.19.




Rys. 7.14. Porównanie charakterystyki konwersji energii systemu fotowoltaicznego - dane rzeczywiste (niebieskie) oraz predykcja modelu LSTM (czerwone) w funkcji promieniowania (prognostowanego).




Rys. 7.15. Porównanie charakterystyki konwersji energii systemu turbiny wiatrowej - dane rzeczywiste (niebieskie) oraz predykcja modelu LSTM (czerwone) w funkcji promieniowania (prognozowanego).




Rys. 7.16. Porównanie mocy wyjściowej instalacji fotowoltaicznej dla wartości rzeczywistych i predykcji modelu LSTM w pełnym horyzoncie testowym (rok 2025).



Rys. 7.17. Porównanie mocy wyjściowej instalacji turbiny wiatrowej dla wartości rzeczywistych i predykcji modelu LSTM w pełnym horyzoncie testowym (rok 2025).



Rys. 7.18. Porównanie mocy wyjściowej instalacji fotowoltaicznej dla wartości rzeczywistych i predykcji modelu LSTM - zbliżenie.



Rys. 7.19. Porównanie mocy wyjściowej instalacji turbiny wiatrowej dla wartości rzeczywistych i predykcji modelu LSTM - zbliżenie.


7.4. Scenariusze sterowania i optymalizacji

HSZ bez magazynowania – scenariusz 1

Aby możliwe było porównanie efektywności działania ocenianych algorytmów sterowania pracą magazynu energii przeprowadzono symulację działania mikrosieci w konfiguracji bez zasobnika energii. Roczny bilans energetyczny oraz ekonomiczny dla tego wariantu przedstawiono na Rys. 7.20. W kolejnych podrozdziałach wyniki te posłużą do weryfikacji skuteczności algorytmu bilansującego (RB) oraz autorskiego algorytmu genetycznego (GA) w harmonogramowaniu pracy magazynu energii.

Analizując wykresy (Rys. 7.20 a i b), można zauważyć niedopasowanie profili generacji i obciążenia. W okresie zimowym zapotrzebowanie na energię (kolor pomarańczowy) drastycznie przewyższa wytwarzanie z lokalnych źródeł OZE. Konsekwencją tego jest znaczący import energii z sieci elektroenergetycznej, który osiąga szczyt na poziomie ok. 2 500 kWh w styczniu, lutym i grudniu. W okresie letnim instalacje OZE generują wystarczająco dużo energii (Rys. 7.20. b), aby pokryć zapotrzebowanie lokalne. Jednak bez magazynu energii nadwyżki te są niemal w całości eksportowane do sieci zasilającej (w lipcu ok. 1500 kWh). Należy zauważyć, że większość energii z systemu OZE generowana jest w godzinach południowych, które charakteryzują się relatywnie niższymi cenami, podczas gdy szczyt zapotrzebowania na energię przypada na godziny wieczorne. To przesunięcie profili generacji i zużycia, w połączeniu z asymetrią cen zakupu i sprzedaży energii, jest zjawiskiem niekorzystnym ekonomicznie.

Takie działanie systemu ma odzwierciedlenie w przepływach finansowych (Rys. 7.20. a). Widoczne są bardzo wysokie ujemne przepływy pieniężne w sezonie zimowym, generujące koszty nawet do -2700 PLN miesięcznie (styczeń i grudzień). W miesiącach letnich przychody ze sprzedaży energii pozwalają tylko na zbilansowanie bieżących kosztów. Takie działanie nie jest w stanie skompensować wysokich kosztów ponoszonych w pozostałej części roku.



Rys. 7.20. Miesięczne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego bez magazynu energii: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii)

HSZ z magazynem energii i algorytmem bilansowania (RB)– scenariusz 2

W drugim etapie badań symulacyjnych do HSZ dołączono magazyn energii, którego sterowanie odbywa się za pomocą algorytmu bilansowania mocą (RB). Jest to obecnie najbardziej powszechny sposób sterowania w instalacjach prosumenckich, którego nadrzędnym celem jest maksymalizacja wskaźnika autokonsumpcji energii z lokalnych źródeł OZE. Algorytm, analogicznie jak w rozdziale 6, nadwyżki energii kierował do magazynu do momentu jego pełnego naładowania. Wszystkie niedobory natomiast pokrywane są z magazynu do chwili osiągnięcia jego minimalnego stanu naładowania. W tym przypadku algorytm ten pełni rolę układu odniesienia. Pozwoli zbadać bazową opłacalność inwestycji w magazyn realnie ocenić skuteczność wdrożonego zaawansowanego algorytmu optymalizacji w scenariuszu 3.

Na Rys. 7.21 przedstawiono zbiorcze wskaźniki efektywności w ujęciu miesięcznym. Analiza wykresów bilansu (Rys. 7.21.a) oraz generacji (Rys. 7.21.b) potwierdza silną zależność pracy systemu od pory roku. W miesiącach zimowych (styczeń-luty, listopad-grudzień) generacja energii z OZE jest ograniczona, a odbiorniki lokalne zużywają całą dostępną energię na bieżąco. W konsekwencji reszta zapotrzebowania zaspokajana jest z sieci


elektroenergetycznej, z której import miesięczny przekracza 2000-2500 kWh. W tym okresie aktywność magazynu energii (Rys. 7.21.d) jest marginalna - słupki wymiany energii są znikomo niskie, co wynika z braku nadwyżek, które mogłyby naładować magazyn. Znajduje to odzwierciedlenie w bilansie finansowym (Rys. 7.21.c), w którym dominują wysokie koszty zakupu energii (słupki ujemne).

W okresie wiosenno-letnim (marzec-październik) aktywność magazynu energii znacząco wzrasta (Rys. 7.21.d). Największy wolumen obrotu energią przez magazyn przypada na miesiące wiosenne (marzec-maj). Należy zauważyć pewne nasycenie w miesiącach letnich (czerwiec-sierpień) - mimo wyższej generacji OZE, aktywność magazynu nie wzrasta proporcjonalnie. Wynika to z faktu, że przy ograniczonej pojemności (50 kWh) magazyn szybko osiąga stan pełnego naładowania, a nadmiar energii musi zostać oddany do sieci (eksport pokazano na Rys. 7.21.a).


Szczegółową analizę pracy w warunkach zimowych przedstawiono na przykładzie danych dziennych ze stycznia (Rys. 7.22.). Wykres wymiany energii (Rys. 7.22.d) potwierdza pasywność systemu - w większości magazyn nie wykonuje żadnej pracy. Potwierdza to przebieg 15-minutowy z dnia 15 stycznia (Rys. 7.24.). Jedynie w niektóre dni instalacja OZE (np. 26 stycznia) generuje nadwyżkę pozwalającą na krótkotrwałą pracę magazynu.

Zupełnie odmienną charakterystykę pracy systemu można zauważyć w sezonie letnim, co zobrazowano na przykładzie lipca (Rys. 7.23.). Wytwarzanie energii OZE każdego dnia wielokrotnie przewyższa zapotrzebowanie, co wymusza regularną, codzienną pracę magazynu (Rys. 7.23.d).


Analiza przebiegu dobowego z 1 lipca (Rys. 7.25) ujawnia jednak ograniczenia prostego sterowania regułowego - w momencie pojawienia się nadwyżek energii magazyn od razu się ładuje. Maksymalny stan naładowania osiąga już ok. godz. 11:00, a przez resztę dnia zostaje pasywny. Nadwyżka energii wysyłana jest do sieci (eksport), często w godzinach niskich cen rynkowych.




Rys. 7.21. Miesięczne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie RB) : a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,




Rys. 7.22. Dzielne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie RB) - styczeń: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 7.23. Dzielne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie RB) - lipiec: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 7.24. 15-minutowe wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie RB) - 15 stycznia: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Działanie magazynu energii, d) Poziom naładowania magazynu energii



Rys. 7.25. 15-minutowe wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie RB) - 1 lipca: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Działanie magazynu energii, d) Poziom naładowania magazynu energii

HSZ z magazynem energii i autorskim algorytmem optymalizacji (GA)– scenariusz 3

Trzeci scenariusz obejmuje implementację autorskiego algorytmu optymalizacji wykorzystującego algorytm genetyczny (GA). W przeciwieństwie do algorytmu bilansującego RB, proponowana metoda podejmuje decyzje sterując instalacją z wyprzedzeniem, w oparciu o prognozy wytwarzania ze źródeł OZE, profilu zapotrzebowania lokalnego oraz dynamicznych cen energii.

Zasadnicza zmiana w logice sterowania dotyczy funkcji celu. Priorytetem algorytmu nie jest już wyłącznie maksymalizacja wskaźnika wykorzystania energii na potrzeby - jak miało to miejsce w scenariuszu RB - lecz maksymalizacja zysku (lub minimalizacja kosztów) w założonym horyzoncie 24-godzinnym.

Na Rys. 7.26. przedstawiono wyniki pracy systemu HSZ sterowanego algorytmem genetycznym w ujęciu rocznym. Analiza bilansu energetycznego (Rys. 7.26. a) potwierdza wyraźną sezonowość pracy układu, ze znaczną nadwyżką eksportu energii w miesiącach letnich. Kluczową różnicę względem metody referencyjnej ujawnia jednak wykres aktywności magazynu (Rys. 7.26. d). W przeciwieństwie do algorytmu RB, sterowanie GA utrzymuje aktywność magazynu przez cały rok. Szczególnie istotne jest zachowanie w miesiącach


zimowych (styczeń, grudzień), gdzie mimo braku generacji PV, wymiana energii z magazynem utrzymuje się na poziomie 200-300 kWh/mc. Znajduje to bezpośrednie odzwierciedlenie w bilansie finansowym (Rys. 7.26.c), gdzie widoczna jest redukcja kosztów dzięki aktywnemu arbitrażowi przez cały rok.

Odmienną strategię system przyjmuje w najtrudniejszych warunkach operacyjnych, tj. w styczniu (Rys. 7.27). Mimo pomijalnie małej generacji z OZE (Rys. 7.27.b), magazyn energii wykazuje selektywną aktywność. Uwagę zwracają dni takie jak 15 stycznia, gdzie dzienny wolumen wymiany energii gwałtownie rośnie nawet do 30 kWh. Jest to dowód na realizację strategii czystego arbitrażu cenowego w odpowiedzi na wystąpienie ekstremalnych cen na rynku bilansującym.


Charakterystykę pracy systemu w warunkach wysokiej generacji OZE przeanalizowano na przykładzie danych dziennych z lipca 2025 r. (Rys. 7.28.). Generacja OZE każdego dnia wielokrotnie przewyższa zapotrzebowanie własne. Algorytm GA reaguje na tą nadpodaż intensywną pracą magazynu energii (Rys. 7.28.d), osiągając dzienną wymianę rzędu 25-35 kWh.

Analiza przebiegu zimowego z dnia 15 stycznia (Rys. 7.29) dostarcza dowodów na wysoką skuteczność działania autorskiego algorytmu w warunkach dużej zmienności cenowej. Tego dnia cena sprzedaży osiągnęła rekordową wartość bliską 1,70 PLN/kWh w godzinach 16:00-18:00 (Rys. 7.29.e). Mimo całkowitego braku generacji PV, algorytm naładował magazyn (wzrost SoC do ok. 60%, Rys. 7.29.d) energią zakupioną z sieci zasilającej po stałej cenie 1,1 PLN/kWh, aby rozładować go w momencie szczytu cenowego (Rys. 7.29.c). Inny przypadek arbitrażu cenowego w okresie letnim przedstawia przebieg dobowy z dnia 1 lipca (Rys. 7.30). Na wykresie cenowym (Rys. 7.30.e) widoczny jest spadek cen sprzedaży energii w godzinach południowych, co algorytm wykorzystuje do ładowania magazynu, podnosząc SoC z poziomu 20% do 80-90% (Rys. 7.30.d). Zgromadzona energia oddawana jest następnie w godzinach wieczornych (po godz. 18:00), idealnie wpasowując się w lokalny szczyt cenowy.


Uzupełnieniem analizy jest przebieg z okresu przejściowego - 17 kwietnia (Rys. 7.31). Dzień ten charakteryzował się dużą zmiennością wytwarzania OZE oraz wystąpieniem ujemnych cen energii w godzinach południowych (Rys. 7.31.e). Algorytm GA poprawnie zidentyfikował te warunki, intensywnie ładując magazyn w południe (Rys. 7.31.c), gromadząc nadwyżki z OZE, by później sprzedać je po do sieci, gdy cena będzie największa (ok. godz. 18:00).




Rys. 7.26. Miesięczne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie GA): a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,




Rys. 7.27. Dzielne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie GA) - styczeń: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,




Rys. 7.28. Dzielne wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solaro-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie GA) - lipiec: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Przepływy pieniężne (suma kosztów zakupu i sprzedaży energii), d) Działanie magazynu energii,



Rys. 7.29. 15-minutowe wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie GA) - 15 stycznia: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Działanie magazynu energii, d) Poziom naładowania magazynu energii, e) Rynkowa Cena Energii - cena sprzedaży powiększona o podatek VAT



Rys. 7.30. 15-minutowe wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie GA) - 1 lipca: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Działanie magazynu energii, d) Poziom naładowania magazynu energii, e) Rynkowa Cena Energii - cena sprzedaży powiększona o podatek VAT



Rys. 7.31. 15-minutowe wyniki uzyskane dla Hybrydowego Systemu Zasilania typu solarno-wiatrowego z magazynem energii o pojemności 50 kWh (sterowanie GA) - 17 kwietnia: a) Bilans energetyczny, b) Generacja i zużycie energii, c) Działanie magazynu energii, d) Poziom naładowania magazynu energii, e) Rynkowa Cena Energii - cena sprzedaży powiększona o podatek VAT

7.5. Analiza porównawcza i dyskusja wyników

W celu ostatecznej weryfikacji postawionej tezy badawczej, dokonano syntezy wyników uzyskanych we wszystkich analizowanych scenariuszach symulacyjnych. W tabeli zbiorczej (Tab. 7.1) zaprezentowano kluczowe wskaźniki techniczno-ekonomiczne dla:

- HSZ bez magazynu energii - scenariusz 1,
- HSZ z magazynem energii i prostym algorytmem bilansowania (RB) - scenariusz 2,
- HSZ z magazynem energii i autorskim algorytmem optymalizacji - scenariusz 3.

Tabela 7.1. Zbiorcze zestawienie wskaźników techniczno-ekonomicznych pracy systemu HSZ dla analizowanych strategii sterowania (dane roczne).

Wskaźnik	Jednostka	Scenariusz 1	Scenariusz 2	Scenariusz 3	Scenariusz 3 (prognoza)
Roczny koszt zakupu energii	PLN	13 024	10 349	9 116	7 238
Koszt degradacji magazynu	PLN	-	724	1 447	1 447
Całkowity koszt z uwzględnieniem kosztów degradacji magazynu	PLN	13 024	11 073	10 564	8685
Energia pobrana z sieci	kWh	14 116	10949	12 861	11 405
Energia oddana do sieci	kWh	8 300	5128	7 046	7 732
Energia ładowania	kWh	-	3518	7 025	7025
Energia rozładowania	kWh	-	3170	6 340	6340
Liczba pełnych cykli	-	-	67	134	134
Procentowa degradacja magazynu	%	-	1,11	2,23	2,23
Wskaźnik autokonsumpcji	%	33	59	43	47

Analiza porównawcza wykazała przewagę autorskiego algorytmu optymalizacyjnego nad rozwiązaniem referencyjnym. Zastosowanie autorskiego algorytmu GA pozwoliło na zredukowanie rocznego całkowitego kosztu (z uwzględnieniem kosztu degradacji baterii) do poziomu -10 564 PLN. Oznacza to osiągnięcie realnych oszczędności rzędu 509 PLN (ok. 5%) względem sterowania regułowego (RB) oraz aż 2 460 PLN (ok. 20%) względem układu bez magazynu energii. Koszt degradacji w scenariuszu z GA (1447 PLN) był ponad dwukrotnie wyższy niż w scenariuszu RB (724 PLN), a mimo to ostateczny bilans finansowy okazał się korzystniejszy. Na tej podstawie w środowisku dużej zmienności cen energii, strategia agresywnego arbitrażu cenowego jest w stanie sfinansować z nawiązką zwiększone zużycie komponentów magazynujących. Algorytm poprawnie identyfikował momenty, w których różnica cen kupna/sprzedaży przewyższała krańcowy koszt degradacji baterii.

Jednym z interesujących wyników badań jest zaobserwowana odwrotna zależność pomiędzy wskaźnikiem autokonsumpcji a zyskiem. Algorytm RB osiągnął najwyższy wskaźnik autokonsumpcji (59%), dążąc do maksymalnego wykorzystania energii OZE na potrzeby własne i minimalizacji wymiany z siecią. Natomiast scenariusz GA osiągnął wskaźnik autokonsumpcji na poziomie zaledwie 43%, jednocześnie wygenerował wyższy zysk. Obniżenie autokonsumpcji jest celowym działaniem optymalizacyjnym. Algorytm GA inteligentnie decydował o sprzedaży energii z OZE w godzinach szczytu cenowego.

Algorytm RB pracował w trybie zachowawczym (67 cykli/rok), traktując magazyn głównie jako bufor nadwyżek. Przy takiej strategii żywotność kalendarzowa baterii prawdopodobnie skończyłaby się wcześniej niż jej żywotność cykliczna. Algorytm GA pracował w trybie aktywnym (134 cykli/rok), wykonując średnio jeden cykl co 2-3 dni. Przekłada się to na roczną degradację pojemności równą 2,23%. Mimo tego, że wartość degradacji magazynu dla GA jest dwukrotnie wyższa niż dla RB, nadal mieści się w bezpiecznych granicach eksploatacyjnych (po 10 latach pojemność spadłaby o ok. 10-20%) [71]. Wyniki te sugerują, że strategie pasywne prowadzą do niedostatecznego wykorzystania potencjału inwestycyjnego (niedostateczna eksploatacja drogiego zasobu, jakim jest magazyn).

Zastosowanie autorskiego algorytmu optymalizacji (GA) pozwoliło na obniżenie kosztu zakupu energii do poziomu 9 116 PLN/rok co pozwoliło poprawić wynik algorytmu RB o 12% (10 349 PLN/rok).

Analiza energii importowanej i eksportowanej wskazuje, że Scenariusz 3 (GA) charakteryzuje się znacznie wyższą dynamiką wymiany z siecią elektroenergetyczną. Energia pobrana z sieci wzrosła z 10 949 kWh (RB) do 12 861 kWh (GA). Energia oddana do sieci wzrosła z 5 128 kWh (RB) do 7 046 kWh (GA).


Analiza różnicy między wynikami symulacji rzeczywistej (Scenariusz 3) a wynikami prognozowanymi pokazuje wpływ dokładności predykcji generacji OZE. Sumaryczne prognozy zakładały dostępność o ok. 2000 kWh więcej energii z OZE w skali roku niż faktycznie zostało wygenerowane.

W wariancie prognoza system przewidywał niższe zapotrzebowanie na import z sieci (11 405 kWh) oraz wyższy eksport (7 732 kWh), co przełożyło się na bardzo niski koszt roczny (7 238 PLN). W rzeczywistości (Scenariusz 3), brakujący wolumen 2 000 kWh energii z OZE był zbilansowany poprzez dodatkowy zakup energii z sieci (wzrost importu do 12 861 kWh) oraz spadek eksportu (do 7 046 kWh). Różnica w wynikach finansowych (rzeczywistych i prognozowanych) nie wynika z błędu algorytmu sterowania, lecz jest bezpośrednim kosztem błędu prognozy meteorologicznej.

7.6. Analiza stabilności czasowej

W celu oceny przydatności autorskiego algorytmu sterowania w systemach czasu rzeczywistego zmierzono niezbędny czas na wygenerowanie optymalnego harmonogramu dla każdego dnia symulacji. W celu weryfikacji tego parametru przeprowadzono analizę statystyczną otrzymanych wyników. Symulacje przeprowadzono na komputerze klasy PC wyposażonym w procesor AMD Ryzen 5 2600 oraz 16 GB RAM.

Przeprowadzona analiza porównawcza (Rys.7.32.) czasów wykonywania algorytmów wykazała dwie istotne przewagi zaproponowanego algorytmu genetycznego z inicjalizacją RB nad klasycznym algorytmem genetycznym.



Rys. 7.32. Czasu obliczeń procesu optymalizacji w pełnym rocznym horyzoncie symulacyjnym dla:
a) autorskiego algorytmu optymalizacji, b) klasycznego algorytmu genetycznego. Wartość liczbową przedstawia
średni czas obliczeń wraz z odchyleniem standardowym ($\mu \pm \sigma$)

Uzyskano redukcję średniego czasu obliczeń o ponad 12% (spadek z 14,17s do 15,91 s). Oznacza to, że zainicjowanie populacji rozwiązaniem regułowym pozwala algorytmowi szybciej osiągnąć zbieżność. Symulacje powtórzono kilkakrotnie, otrzymując podobne rezultaty i proporcje.

Uzyskany czas obliczeń rzędu <1 min jest w pełni akceptowalny dla systemów sterowania EMS, gdzie decyzje podejmowane są w interwałach 15-minutowych. Uzyskana efektywność obliczeniowa stanowi kluczowy fundament dla przyszłych prac badawczych, ukierunkowanych na wdrożenie proponowanej strategii sterowania w horyzoncie kroczącym.

8. PODSUMOWANIE I WNIOSKI

W ramach pracy doktorskiej opracowano, a następnie zweryfikowano autorski system algorytm optymalizacji wykorzystujący metody sztucznej inteligencji do harmonogramowania pracy magazynu energii zintegrowanego z hybrydowym systemem zasilania (HSZ). W skład analizowanego systemu wchodziła instalacja fotowoltaiczna, turbina wiatrowa oraz elektrochemiczny magazyn energii, którego praca była sterowana w sposób predykcyjny z 24-godzinnym horyzontem. Opracowany algorytm optymalizacji, bazujący na metodzie genetycznej (GA), uwzględniał w funkcji celu nie tylko zmienne ceny rynkowe energii i przyszłą generację z OZE, ale również koszty degradacji zasobnika.

Opracowano model matematyczny lokalnego systemu elektroenergetycznego złożonego ze źródeł OZE oraz magazynu energii współpracującego z siecią elektroenergetyczną. Modelowanie oraz symulacje numeryczne przeprowadzono w środowisku MATLAB&Simulink. Kluczowym elementem pracy było opracowanie i implementacja dwóch odmiennych strategii sterowania: opartej na regułach - RB (wykorzystywanej jako algorytm referencyjny) oraz autorskiego algorytmu optymalizacji (opartego na algorytmie genetycznym – GA ze zmodyfikowaną procedurą inicjalizacji populacji). Problem optymalizacyjny sformułowano jako zadanie maksymalizacji całkowitego wyniku finansowego w horyzoncie 24-godzinnym, przy uwzględnieniu ograniczeń technicznych magazynu energii, bilansu energetycznego systemu i kosztów degradacji magazynu. W ramach pracy przeprowadzono wielowariantowe symulacje roczne, porównując efektywność obu algorytmów w odniesieniu do scenariusza bazowego (bez magazynu energii) i referencyjnego. Jako kryteria przyjęto różne pojemności naładowania magazynu energii oraz wymaganie związane ze stanem naładowania magazynu na koniec dnia.

W dalszej części rozprawy przeanalizowano pracę rzeczywistego hybrydowego systemu zasilania z wykorzystaniem danych pomiarowych z obiektu referencyjnego (profil obciążenia, generacja fotowoltaiczna i wiatrowa). Dokonano weryfikacji skuteczności działania hybrydowego podejścia, łączącego predykcję z optymalizacją. Do prognozowania generacji energii z OZE wykorzystano sztuczne sieci neuronowe (LSTM), uczone na podstawie historycznych danych meteorologicznych (obejmujący okres pół roku). Uwzględnienie błędów predykcji w symulacjach pozwoliło na odwzorowanie rzeczywistych warunków eksploatacji i ocenę odporności algorytmu GA na niepewność danych wejściowych. Wykazano, że mimo zmiennego charakteru pogody, proponowany system sterowania generuje wymierne korzyści ekonomiczne.

Przeprowadzone symulacje, w których porównano wyniki uzyskane dla autorskiego algorytmu optymalizacyjnego (GA) z powszechnie stosowaną metodą regułową (RB), pozwalają na sformułowanie następujących wniosków końcowych:

- Opracowany model hybrydowego systemu zasilania może być wykorzystany do analiz techniczno-ekonomicznych dla różnych algorytmów optymalizacji.
- Zaproponowany algorytm genetyczny (GA) w większości scenariuszy osiągnął lepsze wyniki ekonomiczne niż algorytm regułowy (RB), osiągając niższy roczny koszt energii HSZ, dzięki wykonywaniu arbitrażu cenowego.
- Zastosowanie SSN typu LSTM do prognozowania wytwarzania energii z OZE zapewnia dostateczną dokładność predykcji, niezbędną do skutecznego planowania harmonogramu pracy magazynu w horyzoncie dobowym, szczególnie w przypadku instalacji fotowoltaicznych.
- Badania ujawniły brak bezpośredniej korelacji między maksymalizacją autokonsumpcji a zyskiem finansowym w systemach z taryfami dynamicznymi. Autorski algorytm GA osiągnął lepszy wynik finansowy przy niższym wskaźniku autokonsumpcji niż algorytm RB, co dowodzi, że w pewnych warunkach rynkowych korzystniejszy jest handel energią niż jej magazynowanie na własne potrzeby.
- Opracowane rozwiązanie stanowi gotowe narzędzie, które może wspierać proces transformacji energetycznej, umożliwiając prosumantom i operatorom mikrosieci efektywnie zarządzanie magazynem energii w warunkach nowoczesnego rynku energii.
- Osiągnięty w niniejszej pracy margines czasowy (czas obliczeń dla 1 dnia $>1\text{min}$) umożliwia w przyszłości przejście z modelu planowania dobowego na model cyklicznej optymalizacji (np. co 15min). Taki kierunek rozwoju pozwoliłby na bieżącą kompensację błędów prognoz meteorologicznych wykorzystując sprzężenie zwrotne, co stanowi naturalny kolejny etap rozwoju prezentowanego algorytmu/systemu.
- W tej pracy, do sprawdzenia działania opracowanego algorytmu harmonogramowania wykorzystano magazyn energii elektrycznej. Jest to jeden z przykładów możliwości zastosowania tego algorytmu, ponieważ otrzymane wyniki badań jednoznacznie wskazują, że jest to narzędzie uniwersalne, które może zostać wykorzystane do pracy z dowolnym magazynem energii.

LITERATURA

- [1] Abdolrasol, M., Mohamed, R., Hannan, M., Al-Shetwi, A., Mansor, M., & Blaabjerg, F. (2021). Artificial Neural Network Based Particle Swarm Optimization for Microgrid Optimal Energy Scheduling. *IEEE Transactions on Power Electronics*, 36(11), 12151–12157. <https://doi.org/10.1109/TPEL.2021.3074964>.
- [2] Ahmed, N. A., Miyatake, M., & Al-Othman, A. K. (2009). Hybrid solar photovoltaic/wind turbine energy generation system with voltage-based maximum power point tracking. *Electric Power Components and Systems*, 37(1), 43–60. <https://doi.org/10.1080/15325000802322012>.
- [3] Anilkumar, T. T., Simon, S. P., & Padhy, N. P. (2017). Residential electricity cost minimization model through open well-pico turbine pumped storage system. *Applied Energy*, 195, 23–35. <https://doi.org/10.1016/j.apenergy.2017.03.020>.
- [4] Ali, M. A., Besheer, A. H., Emara, H. M., & Bahgat, A. (2025). Optimal micro-grid battery scheduling within a comprehensive smart pricing scheme. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-02690-9>
- [5] Ali, A. H., & Najafi, A. (2022). Optimization and Performance Improvement of Grid-Connected PV Plant Based on ANN-PSO and P&O Algorithms. *International Transactions on Electrical Energy Systems*, 2022. <https://doi.org/10.1155/2022/1278492>
- [6] Al-Rawajfeh, M. A., & Gomaa, M. R. (2023). Comparison between horizontal and vertical axis wind turbine. *International Journal of Applied Power Engineering*, 12(1), 13–23. <https://doi.org/10.11591/ijape.v12.i1.pp13-23>.
- [7] Aslam, S., Khalid, A., & Javaid, N. (2020). Towards efficient energy management in smart grids considering microgrids with day-ahead energy forecasting. *Electric Power Systems Research*, 182. <https://doi.org/10.1016/j.epsr.2020.106232>
- [8] Bayrak, Z. U., Bayrak, G., Ozdemir, M. T., Gencoglu, M. T., & Cebeci, M. (2016). A low-cost power management system design for residential hydrogen & solar energy based power plants. *International Journal of Hydrogen Energy*, 41(29), 12569–12581. <https://doi.org/10.1016/j.ijhydene.2016.01.093>.

- [9] Borkowski B., Mączka T., Szulc P., Założenia wstępne dla Systemu Zarządzania hybrydowymi instalacjami OZE dla krajowych przedsiębiorstw z sektora MŚP. *Energetyka*. 2021, nr 12, s. 786-792.
- [10] Breton, S. P., & Moe, G. (2009). Status, plans and technologies for offshore wind turbines in Europe and North America. *Renewable Energy*, 34(3), 646–654. <https://doi.org/10.1016/j.renene.2008.05.040>.
- [11] Calderón, M., Calderón, A. J., Ramiro, A., & González, J. F. (2009). Automatic management of energy flows of a stand-alone renewable energy with support of hydrogen. *Renewable Energy and Power Quality Journal*, 1(7), 346–350. <https://doi.org/10.24084/repqj07.347>.
- [12] Chakraborty, A., & Ray, S. Operational cost minimization of a microgrid with optimum battery energy storage system and plug-in-hybrid electric vehicle charging impact using slime mould algorithm. *Energy* 2023, 278. <https://doi.org/10.1016/j.energy.2023.127842>.
- [13] Chouhan, S., Tiwari, D., Inan, H., Khushalani-Solanki, S., & Feliachi, A. (2016). DER optimization to determine optimum BESS charge/discharge schedule using linear programming. *2016 IEEE Power and Energy Society General Meeting (PESGM)*, 1–5. <https://doi.org/10.1109/PESGM.2016.7741576>.
- [14] Danielsson, G. H., da Silva, L. N. F., da Paixão, J. L., Abaide, A. da R., & Neto, N. K. (2025). Rules-Based Energy Management System for an EV Charging Station Nanogrid: A Stochastic Analysis. *Energies*, 18(1). <https://doi.org/10.3390/en18010026>.
- [15] Dokumentacja techniczna Matlab, <https://www.mathworks.com/help/gads/how-the-genetic-algorithm-works.html>
- [16] Dyrektywa Parlamentu Europejskiego i Rady (UE) 2019/944 z dnia 5 czerwca 2019 r. w sprawie wspólnych zasad rynku wewnętrznego energii elektrycznej oraz zmieniająca dyrektywę 2012/27/UE
- [17] Elalfy, D. A., Gouda, E., Kotb, M. F., Bureš, V., & Sedhom, B. E. (2024). Comprehensive review of energy storage systems technologies, objectives, challenges, and future trends. In *Energy Strategy Reviews* (Vol. 54). Elsevier Ltd. <https://doi.org/10.1016/j.esr.2024.101482>.
- [18] ENEA Operator sp. z o.o. IRiESD – wersja 2.3. (tekst ujednolicony).

- [19] Eurostat, Dostęp 31.12.2025r. z: <https://ec.europa.eu/eurostat/>
- [20] Furat D., Shafiullah GM, Anda M., Stand-Alone Microgrid with 100% Renewable Energy: A Case Study with Hybrid Solar PV-Battery-Hydrogen, Sustainability 2020, 12, 2047.
- [21] Gajewski, P., & Pieńkowski, K. (2021). Control of the hybrid renewable energy system with wind turbine, photovoltaic panels and battery energy storage. Energies, 14(6). <https://doi.org/10.3390/en14061595>.
- [22] González-Romera, E.; Ruiz-Cortés, M.; Milanés-Montero, M.-I.; Barrero-González, F.; Romero-Cadaval, E.; Lopes, R.A.; Martins, J. Advantages of Minimizing Energy Exchange Instead of Energy Cost in Prosumer Microgrids. Energies 2019, 12, 719. <https://doi.org/10.3390/en12040719>.
- [23] Hai, T., Zhou, J., Rezvani, A., Le, B. N., & Oikawa, H. (2023). Optimal energy management strategy for a renewable based microgrid with electric vehicles and demand response program. Electric Power Systems Research, 221. <https://doi.org/10.1016/j.epsr.2023.109370>.
- [24] Han, G., Lee, S., Lee, J., Lee, K., & Bae, J. (2021). Deep-learning- and reinforcement-learning-based profitable strategy of a grid-level energy storage system for the smart grid. Journal of Energy Storage, 41. <https://doi.org/10.1016/j.est.2021.102868>
- [25] Huang, K., Zhou, Y., Mei, Y., Chang, F. J., & Xu, C. Y. (2025). Boosting Efficiency: Optimizing Pumped-Storage Power Station Operation by a Mixed Integer Linear Programming Approach. Energies, 18(18). <https://doi.org/10.3390/en18184977>.
- [26] Hussain, A., & Kim, H. M. (2025). A Rule-Based Modular Energy Management System for AC/DC Hybrid Microgrids. Sustainability (Switzerland), 17(3). <https://doi.org/10.3390/su17030867>.
- [27] Ibrahim, O., Bakare, M. S., Amosa, T. I., Otuoze, A. O., Owonikoko, W. O., Ali, E. M., Adesina, L. M., & Ogunbiyi, O. (2023). Development of fuzzy logic-based demand-side energy management system for hybrid energy sources. Energy Conversion and Management: X, 18. <https://doi.org/10.1016/j.ecmx.2023.100354>.
- [28] IRENA (2025), Renewable capacity statistics 2024, International Renewable Energy Agency, Abu Dhabi.

- [29] Ismail, N. .; Mat Said, D.; Mirsaeidi, S.; Ahmad, N. .; Rosmin, N. .; Hussin, S. M. .; Abd Wahid, S. A. .; Mohd Yassin, Z. I. .; Zainal, N. H. . Modeling and Analysis of Simplified PV Module With Various Temperature And Irradiance Inputs Using MATLAB Simulink Algorithm. *Elektrika* 2022, 21, 28-39.
- [30] Jamal, S., Pasupuleti, J., & Ekanayake, J. (2024). A rule-based energy management system for hybrid renewable energy sources with battery bank optimized by genetic algorithm optimization. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-54333-0>.
- [31] Kang, H., Jung, S., Kim, H., Jeoung, J., & Hong, T. (2024). Reinforcement learning-based optimal scheduling model of battery energy storage system at the building level. *Renewable and Sustainable Energy Reviews*, 190. <https://doi.org/10.1016/j.rser.2023.114054>
- [32] Kang, D., Kang, D., Hwangbo, S., Niaz, H., Lee, W. B., Liu, J. J., & Na, J. (2023). Optimal planning of hybrid energy storage systems using curtailed renewable energy through deep reinforcement learning. *Energy*, 284. <https://doi.org/10.1016/j.energy.2023.128623>
- [33] Katiraei, F.; Iravani, R.; Hatziargyriou, N.; Dimeas, A. Microgrids management. *IEEE Power Energy Mag.* 2008, 6, 54–65.
- [34] Khalid, M., Ahmadi, A., Savkin, A. v., & Agelidis, V. G. (2016). Minimizing the energy cost for microgrids integrated with renewable energy resources and conventional generation using controlled battery energy storage. *Renewable Energy*, 97, 646–655. <https://doi.org/10.1016/j.renene.2016.05.042>.
- [35] Klausmann, F., & Klingler, A. L. (2023). Adaptive Control Strategy for Stationary Electric Battery Storage Systems with Reliable Peak Load Limitation at Maximum Self-Consumption of Locally Generated Energy. *Energies*, 16(9). <https://doi.org/10.3390/en16093964>
- [36] Kusakana, K. (2019). Optimal electricity cost minimization of a grid-interactive Pumped Hydro Storage using ground water in a dynamic electricity pricing environment. *Energy Reports*, 5, 159–169. <https://doi.org/10.1016/j.egyr.2019.01.004>.

- [37] Lee, S.-J.; Yoon, Y. Electricity Cost Optimization in Energy Storage Systems by Combining a Genetic Algorithm with Dynamic Programming. *Mathematics* 2020, 8, 1526. <https://doi.org/10.3390/math8091526>.
- [38] Li, F., Shi, Z., Zhu, Z., & Gan, Y. (2025). Energy Management Strategy for Direct Current Microgrids with Consideration of Photovoltaic Power Tracking Optimization. *Energies*, 18(2). <https://doi.org/10.3390/en18020252>.
- [39] Li, Y.; Peng, J.; Jia, H.; Zou, B.; Hao, B.; Ma, T.; Wang, X. Optimal Battery Schedule for Grid-Connected Photovoltaic-Battery Systems of Office Buildings Based on a Dynamic Programming Algorithm. *J. Energy Storage* 2022, 50, 104557.
- [40] Liu, Y., Lu, Q., Yu, Z., Chen, Y., & Yang, Y. (2024). Reinforcement Learning-Enhanced Adaptive Scheduling of Battery Energy Storage Systems in Energy Markets. *Energies*, 17(21). <https://doi.org/10.3390/en17215425>
- [41] Liemthong, R.; Srithapon, C.; Ghosh, P.K.; Chatthaworn, R. Home Energy Management Strategy-Based Meta-Heuristic Optimization for Electrical Energy Cost Minimization Considering TOU Tariffs. *Energies* 2022, 15, 537. <https://doi.org/10.3390/en15020537>.
- [42] Lin, W.-M.; Tu, C.-S.; Tsai, M.-T. Energy Management Strategy for Microgrids by Using Enhanced Bee Colony Optimization. *Energies* 2016, 9, 5. <https://doi.org/10.3390/en9010005>.
- [43] Lee, Y. R., Kim, H. J., & Kim, M. K. (2021). Optimal operation scheduling considering cycle aging of battery energy storage systems on stochastic unit commitments in microgrids. *Energies*, 14(2).
- [44] Martínez-Caballero, L.; Kot, R.; Milczarek, A.; Malinowski, M. Comparison of Energy Storage Management Techniques for a Grid-Connected PV- and Battery-Supplied Residential System. *Electronics*, 2024, 13, 87. <https://doi.org/10.3390/electronics13010087>.
- [45] Martinez-Rico, J., Zulueta, E., de Argandona, I. R., Fernandez-Gamiz, U., & Armendia, M. (2021). Multi-objective Optimization of Production Scheduling Using Particle Swarm Optimization Algorithm for Hybrid Renewable Power Plants with Battery Energy Storage System. *Journal of Modern Power Systems and Clean Energy*, 9(2), 285–294. <https://doi.org/10.35833/MPCE.2019.000021>

- [46] Miłek, D.; Nowak, P.; Latosińska, J. The Development of Renewable Energy Sources in the European Union in the Light of the European Green Deal. *Energies* 2022, 15, 5576. <https://doi.org/10.3390/en15155576>.
- [47] Mota, B., Faria, P., & Vale, Z. (2024). Energy cost optimization through load shifting in a photovoltaic energy-sharing household community. *Renewable Energy*, 221. <https://doi.org/10.1016/j.renene.2023.119812>.
- [48] Mumtahina, U., Alahakoon, S., & Wolfs, P. (2025). A Day-Ahead Optimal Battery Scheduling Considering the Grid Stability of Distribution Feeders. *Energies*, 18(5). <https://doi.org/10.3390/en18051067>
- [49] Nurunnabi Md., Roy N. K., Grid Connected Hybrid Power System Design Using HOMER, 3rd International Conference on Advances in Electrical Engineering 17-19 December, 2015, Dhaka, Bangladesh.
- [50] Park, S., Oh, J., & Hwang, E. (2024). Metaheuristic Algorithm-Based Optimal Energy Operation Scheduling and Energy System Sizing Scheme for PV-ESS Integrated Systems in South Korea. *International Journal of Energy Research*, 2024(1). <https://doi.org/10.1155/2024/1992135>
- [51] Praca zbiorowa pod redakcją: Gałusza M., Paruch J., Odnawialne i niekonwencjonalne źródła energii, Wydawnictwo Tarbonus, Kraków 2008.
- [52] Pocola, T. O., Robu, V., Rietveld, J., Norbu, S., Couraud, B., Andoni, M., Flynn, D., & Poor, H. V. (2025). Optimal sizing and control of a grid-connected battery in a stacked revenue model including an energy community. *Applied Energy*, 397. <https://doi.org/10.1016/j.apenergy.2025.126122>
- [53] Rafał, K.; Radziszewska, W.; Grabowski, O.; Biedka, H.; Verstraete, J. Energy Cost Minimization with Hybrid Energy Storage System Using Optimization Algorithm. *Appl. Sci.* 2023, 13, 518. <https://doi.org/10.3390/app13010518>.
- [54] Ragab, Z., Pashajavid, E., & Rajakaruna, S. (2024). Optimal Sizing and Economic Analysis of Community Battery Systems Considering Sensitivity and Uncertainty Factors. *Energies*, 17(18). <https://doi.org/10.3390/en17184727>
- [55] Rouzbahani, H. M., Karimipour, H., & Lei, L. (2021). A review on virtual power plant for energy management. In *Sustainable Energy Technologies and Assessments* (Vol. 47). Elsevier Ltd. <https://doi.org/10.1016/j.seta.2021.101370>.

- [56] Roy, C., & Kumar Das, D. (n.d.). A hybrid genetic algorithm (GA)-particle swarm optimization (PSO) algorithm for demand side management in smart grid considering wind power for cost optimization. <https://doi.org/10.1007/s12046-021-01626-zS>.
- [57] Secchi, M., Barchi, G., Macii, D., Moser, D., & Petri, D. (2021). Multi-objective battery sizing optimisation for renewable energy communities with distribution-level constraints: A prosumer-driven perspective. *Applied Energy*, 297. <https://doi.org/10.1016/j.apenergy.2021.117171>
- [58] Serwis internetowy: Open-Meteo, dostęp: <https://open-meteo.com/>.
- [59] Serwis internetowy: Polskie Sieci Elektroenergetyczne, dostęp: <https://www.pse.pl/home>.
- [60] Serwis internetowy: PVmonitor, dostęp: <https://pvmonitor.pl/>.
- [61] Serwis internetowy: Urząd Regulacji Energetyki, dostęp: <https://www.ure.gov.pl/>.
- [62] Sushil Kumar Bhoi, Manas Ranjan Nayak, Optimal scheduling of battery storage with grid tied PV systems for trade-off between consumer energy cost and storage health, *Microprocessors and Microsystems*, Volume 9, 2020, 103274, ISSN 0141-9331, <https://doi.org/10.1016/j.micpro.2020.103274>.
- [63] Talluri, G., Lozito, G. M., Grasso, F., Iturrino Garcia, C., & Luchetta, A. (2021). Optimal battery energy storage system scheduling within renewable energy communities. *Energies*, 14(24). <https://doi.org/10.3390/en14248480>
- [64] Thirunavukkarasu, G.S.; Seyedmahmoudian, M.; Jamei, E.; Horan, B. ; Mekhilef, S.; Stojcevski, A. Role of optimization techniques in microgrid energy management systems—a review. *Energy Strategy Rev.*, 43 (2022), <https://doi.org/10.1016/j.esr.2022.100899>.
- [65] Türkay B.E., Telli A.Y., Economic analysis of standalone and grid connected hybrid energy systems, *Renewable Energy*, Volume 36, Issue 7, 2011, s. 1931-1943.
- [66] Ustawa z dnia 20 lutego 2015 r. o odnawialnych źródłach energii (Dz.U. z 2024 r. poz. 1077, z późn. zm.)

- [67] Rajagopalan, A., Nagarajan, K., Montoya, O. D., Dhanasekaran, S., Kareem, I. A., Perumal, A. S., Lakshmaiya, N., & Paramasivam, P. (2022). Multi-Objective Optimal Scheduling of a Microgrid Using Oppositional Gradient-Based Grey Wolf Optimizer. *Energies*, 15(23). <https://doi.org/10.3390/en15239024>
- [68] Real, A. C., Luz, G. P., Sousa, J. M. C., Brito, M. C., & Vieira, S. M. (2024). Optimization of a photovoltaic-battery system using deep reinforcement learning and load forecasting. *Energy and AI*, 16. <https://doi.org/10.1016/j.egyai.2024.100347>
- [69] Ullah, Z., Qazi, H. S., Rehman, A. U., Hasanien, H. M., Wang, S., Elkadeem, M. R., & Badshah, F. (2024). Efficient energy management of domestic loads with electric vehicles by optimal scheduling of solar-powered battery energy storage system. *Electric Power Systems Research*, 234. <https://doi.org/10.1016/j.epsr.2024.110570>
- [70] Weckesser, T., Dominković, D. F., Blomgren, E. M. V., Schledorn, A., & Madsen, H. (2021). Renewable Energy Communities: Optimal sizing and distribution grid impact of photo-voltaics and battery storage. *Applied Energy*, 301. <https://doi.org/10.1016/j.apenergy.2021.117408>
- [71] Xu, B., Oudalov, A., Ulbig, A., Andersson, G., & Kirschen, D. S. (2018). Modeling of lithium-ion battery degradation for cell life assessment. *IEEE Transactions on Smart Grid*, 9(2), 1131–1140. <https://doi.org/10.1109/TSG.2016.2578950>
- [72] Zhang Y., Wei W., Model construction and energy management system of lithium battery, PV generator, hydrogen production unit and fuel cell in islanded AC microgrid, *International Journal of Hydrogen Energy*, Volume 45, Issue 33, 2020, s. 16381-16397
- [73] Zia, M.F.; Elbouchikhi, E.; Benbouzid, M. Microgrids energy management systems: A critical review on methods, solutions, and prospects. *Appl. Energy* 2018, 222, 1033–1055.