



POLITECHNIKA ŚLĄSKA
WYDZIAŁ ELEKTRYCZNY
KATEDRA ELEKTROENERGETYKI I STEROWANIA UKŁADÓW

ROZPRAWA DOKTORSKA

**Analiza i optymalizacja pracy układu zasilania odbiorcy
indywidualnego wyposażonego w źródło fotowoltaiczne**

Autor: **mgr inż. Tomasz Paweł NACZYŃSKI**
Promotor: **dr hab. inż. Roman KORAB, prof. PŚ**
Promotor pomocniczy: **dr inż. Marcin POŁOMSKI**

Gliwice 2025

PODZIĘKOWANIA

W trakcie realizowania doktoratu otrzymałem znaczące wsparcie oraz pomoc. Dlatego chciałbym serdecznie podziękować:

- W pierwszej kolejności chciałbym podziękować mojemu promotorowi dr hab. inż. Romanowi Korabowi, prof. PŚ, za motywację, inspirację oraz pieczę, jaką poświęcił podczas trwania realizacji tego doktoratu. Otrzymane wsparcie pozwoliło mi ukierunkować tematykę badań oraz motywowało mnie do zgłębnienia wiedzy w różnych tematach, umożliwiając zobaczenie szerszej perspektywy realizowanych badań.
- Chciałbym podziękować promotorowi pomocniczemu dr inż. Marcinowi Połomskiemu za pomoc, inspirację i wsparcie, których udzielał w czasie trwania doktoratu. Pomoc związana z zrozumieniem i opanowaniem aspektów związanych z językami programowania oraz sposobem wdrożenia kodów programu w algorytmach sterowania urządzeniami.
- Mojej opiekun, współpracownikom, znajomym, którzy towarzyszyli mi podczas realizacji doktoratu. W szczególności chciałbym podziękować mgr inż. Marcinowi Smółce, z którym wymieniałem się doświadczeniami i omawiałem problemy.
- Dziękuję także mojej rodzinie za wsparcie, bez którego nie byłoby mnie w tym miejscu.

STRESZCZENIE PRACY

Rosnąca popularność mikroinstalacji fotowoltaicznych (PV) montowanych przez odbiorców indywidualnych przyczynia się do okresowego występowania niekorzystnych zjawisk w systemie elektroenergetycznym, a głównym tego powodem jest zbyt wysoka generacja tych źródeł względem rzeczywistego zużycia energii w poszczególnych budynkach mieszkalnych, co sprawia, że nadmiar produkowanej energii jest oddawany do sieci elektroenergetycznej. Działania zaradcze podejmowane przez operatorów systemów dystrybucyjnych, polegające na modernizacji i rozbudowie sieci, poprawiają sytuację jedynie przez krótki czas, zazwyczaj do momentu przyłączenia kolejnych mikroinstalacji na danym obszarze. Ponadto działania te są bardzo kosztowne, a ich realizacja trwa latami. Dlatego pożądane jest znalezienie alternatywnego rozwiązania, umożliwiającego zwiększenie poziomu autokonsumpcji energii generowanej przez mikroinstalacje PV i tym samym zmniejszenie ilości energii oddawanej przez prosumentów do sieci elektroenergetycznej. Aby było to możliwe należy opracować system zarządzania generowaną energią w miejscu jej wytworzenia, który będzie realizował następujące funkcje:

- pomiarową – monitorującą aktualne parametry charakteryzujące pracę instalacji zasilającej w rozpatrywanym budynku, w tym generację w źródle PV,
- prognostyczną – polegającą na przygotowaniu prognozowanych profili zapotrzebowania bazowego budynku oraz generacji energii w mikroinstalacji PV z nim zintegrowanej,
- optymalizującą – służącą do opracowania planu pracy magazynu energii oraz odbiorników o elastycznym czasie załączania, w sposób realizujący zadaną funkcję celu,
- sterującą – kontrolującą pracę magazynu energii i wybranych odbiorników zgodnie z opracowanym planem pracy tych urządzeń.

Zaprojektowanie i wdrożenie systemu, który będzie realizował wyżej wymienione funkcje będzie krokiem naprzód w stronę efektywnego zarządzania energią elektryczną w obrębie pojedynczego budynku wyposażonego w mikroinstalację PV, magazyn energii oraz odbiorniki o elastycznym czasie załączania. W rozprawie została przedstawiona propozycja systemu zarządzania energią w budynku mieszkalnym (Home Energy Management System – HEMS), który jest możliwy do praktycznego wdrożenia zarówno w nowo budowanych, jak i istniejących, tego typu obiektach.

SPIS TREŚCI

1.	WSTĘP	5
2.	TEZA, CEL I ZAKRES PRACY	9
3.	OPIS OSIĄGNIĘĆ NAUKOWYCH	11
3.1.	Metoda prognozowania bazowego zapotrzebowania na energię elektryczną odbiorcy komunalno-bytowego	11
3.2.	Metoda prognozowania generacji energii elektrycznej w źródle fotowoltaicznym na podstawie numerycznej prognozy pogody	14
3.3.	Algorytm optymalizujący pracę urządzeń elektrycznych zainstalowanych u odbiorcy komunalno-bytowego	22
4.	OPIS OSIĄGNIĘĆ WDROŻENIOWYCH	34
4.1.	Charakterystyka obiektu (budynku jednorodzinnego) i urządzeń elektrycznych w nim zainstalowanych	34
4.2.	Rozbudowa układu pomiarowego zainstalowanego w rozpatrywanym budynku mieszkalnym	37
4.2.1.	Układ do pomiaru parametrów charakteryzujących pracę instalacji zasilającej w budynku	37
4.2.2.	Układ do pomiaru parametrów charakteryzujących pracę poszczególnych urządzeń elektrycznych	40
4.3.	Home Assistant jako otwarta platforma pomiarowo-sterująca	45
4.3.1.	Home Assistant – funkcje pomiarowe	45
4.3.2.	Home Assistant – funkcje sterujące	52
5.	OCENA EFEKTÓW IMPLEMENTACJI OPRACOWANEGO SYSTEMU HEMS W RZECZYWISTYM ŚRODOWISKU PRACY	62
5.1.	Sterowanie magazynem za pomocą algorytmu opartego na regułach logicznych	63
5.2.	Sterowanie magazynem za pomocą algorytmu opartego na metodzie optymalizacji w sposób minimalizujący koszty energii elektrycznej	73
5.3.	Sterowanie magazynem za pomocą algorytmu opartego na metodzie optymalizacji w sposób maksymalizujący neutralność finansową prosumenta	79
6.	PODSUMOWANIE I NAJWAŻNIEJSZE WNIOSKI	85
7.	BIBLIOGRAFIA	88
Załącznik.	ZBIÓR POWIĄZANYCH TEMATYCZNIE ARTYKUŁÓW NAUKOWYCH STANOWIĄCYCH ROZPRAWĘ DOKTORSKĄ	91

1. WSTĘP

W ostatnich kilku latach widoczny jest niezwykle dynamiczny przyrost liczby i mocy prosumenckich mikroinstalacji fotowoltaicznych (PV) przyłączanych do sieci niskiego napięcia (nN). Według stanu na koniec maja 2025 roku, sumaryczna liczba mikroinstalacji PV przyłączonych do sieci rozdzielczej nN należącej do Operatorów Systemów Dystrybucyjnych (OSD) w Polsce wyniosła ponad 1,5 mln, a ich łączna moc zainstalowana przekroczyła 12,8 GW [1]. Rozwojowi tego segmentu wytwarzania nie towarzyszy jednak adekwatny rozwój metod i narzędzi pozwalających na optymalne zarządzanie wykorzystaniem generowanej energii w miejscu jej produkcji, z uwzględnieniem czasu, w którym ta produkcja występuje.

Obecnie, w gospodarstwach domowych wyposażonych w źródła fotowoltaiczne, średnio tylko około 30% generowanej energii jest zużywane w chwili jej wyprodukowania [2], co wynika z niejednoczesności czasowej generacji i poboru energii w tego typu obiektach (maksymalna generacja energii w źródłach fotowoltaicznych następuje głównie w godzinach okołopołudniowych, podczas gdy największe zużycie energii przez odbiorcę komunalno-bytowego ma miejsce w godzinach późno popołudniowych i wieczornych). Nadmiar generowanej energii jest również rzadko magazynowany w domowych zasobnikach energii elektrycznej. W efekcie, nadwyżki wyprodukowanej przez prosumentów energii są oddawane do sieci nN. Następstwem takiej sytuacji jest możliwość występowania w ciągu doby okresów, w których moc generowana przez wszystkie instalacje fotowoltaiczne przyłączone do danego fragmentu sieci nN jest na tyle duża, że powoduje powstawanie zakłóceń w pracy tej sieci, obejmujących m.in. [3 – 11]:

1. wzrost napięcia powyżej wartości dopuszczalnej, tj. $110\% U_n$ (U_n – napięcie znamionowe sieci),
2. przekroczenie prądu dopuszczalnego długotrwale dla danego elementu sieci,
3. pojawienie się odwrotnych przepływów mocy czynnej, czyli przepływów z sieci niskiego napięcia do sieci średniego napięcia (SN),
4. wzrost strat sieciowych w stosunku do pracy tej samej sieci bez źródeł PV,
5. wzrost niesymetrii napięć (głównie składowej zerowej).

W konsekwencji, w wielu obszarach kraju, szczególnie zasilanych z terenowych sieci nN, wyczerpują się możliwości przyłączania nowych źródeł fotowoltaicznych do sieci elektroenergetycznej, czego najłatwiej zauważalnym objawem są występujące tam przerwy w pracy mikroinstalacji PV w słoneczne dni, spowodowane wyłączeniem falowników przez ich zabezpieczenia nadnapięciowe.

W reakcji na pojawiające się problemy możliwe jest zastosowanie szeregu rozwiązań technicznych poprawiających warunki pracy sieci nN o dużym nasyceniu źródłami PV. Należą do nich m.in. [12 – 17]:

1. stosowanie transformatorów o zwiększonej mocy w stosunku do zapotrzebowania odbiorców, a także transformatorów z podobciążeniową regulacją napięcia,
2. montaż urządzeń do kompensacji mocy biernej (np. SVC lub STATCOM) oraz regulatorów napięcia,
3. sterowanie pracą falowników w instalacjach PV (zmiana współczynnika mocy),
4. wymiana przewodów roboczych linii nN na przewody o większych przekrojach,
5. zmiana punktów podziału sieci nN,
6. budowa nowych stacji transformatorowych SN/nN i skracanie istniejących obwodów sieci nN.

Wymieniony zestaw działań nie likwiduje jednak głównej przyczyny decydującej o powstawaniu zakłóceń w pracy sieci nN z dużym udziałem źródeł PV, jaką jest specyficzny lokalny bilans mocy, wynikający z niskiego obciążenia odbiorców oraz wysokiej generacji PV. Rozwiązaniem, które pozwoli na poprawę tego stanu jest zwiększenie poboru energii w miejscu jej wytworzenia, w tym samym czasie, w którym to wytwarzanie następuje. Można to uzyskać przez właściwe sterowanie wybranymi odbiornikami oraz przede wszystkim dzięki wykorzystaniu zasobnika (magazynu) energii, przyłączonego w układzie zasilania prosumenta i sterowanego według odpowiedniego algorytmu.


Możliwości kształtowania bilansu energii elektrycznej odbiorcy indywidualnego wyposażonego w źródło fotowoltaiczne zostały wstępnie przeanalizowane w publikacji [Z.1], wchodzącej w skład omawianego zbioru powiązanych tematycznie artykułów naukowych stanowiących rozprawę doktorską (Załącznik Z.1). W artykule tym skupiono się na wstępnej analizie i możliwym sposobie rozwiązania problemu związanego z niskim wykorzystaniem na własne potrzeby energii generowanej w źródle fotowoltaicznym. Pierwszym krokiem przeprowadzonych badań było zainstalowanie w budynku jednorodzinnym miernika parametrów sieci Lumel P43, współpracującego z mikrokomputerem Raspberry Pi. Za pomocą tego układu zostały zarejestrowane różne wielkości charakteryzujące pracę instalacji elektrycznej w budynku. Uzyskane dane pomiarowe poddano szczegółowej analizie, która wykazała znaczącą rozbieżność profilu generacji źródła PV z profilem zużycia energii w budynku, efektem czego była niewielka autokonsumpcja oraz wysoka wymiana energii z siecią elektroenergetyczną.

W kolejnym etapie badań, aby zwiększyć poziom autokonsumpcji i tym samym zminimalizować wymianę z siecią, postanowiono przeanalizować możliwość sterowania wybranymi odbiornikami w taki sposób, aby załączać je w okresie wysokiej generacji PV, zamiast w godzinach popołudniowo-wieczornych. Uwzględniono również możliwość magazynowania części generowanej energii w zasobniku bateryjnym. W celu pogłębionej oceny potencjału zwiększenia wykorzystania generowanej przez źródło PV energii, opracowano w programie LabVIEW model symulacyjny szczegółowo odwzorowujący analizowany budynek. Za pomocą skonstruowanego modelu przeprowadzono wielowariantowe symulacje z wykorzystaniem zarejestrowanych wcześniej danych dotyczących generacji PV oraz zapotrzebowania całego budynku, jak i poszczególnych odbiorników. Stwierdzono, że po zastosowaniu sterowania wybranymi odbiornikami oraz magazynowania energii dla przykładowego dnia poddanego analizie poziom autokonsumpcji generowanej energii zwiększył się z 11,3% do 36,9%, natomiast wymiana energii z siecią elektroenergetyczną zmniejszyła się z 30,9 kWh do 19,3 kWh.

Wykonane wielowariantowe symulacje potwierdziły zatem przypuszczenie, że u odbiorcy komunalno-bytowego wyposażonego w źródło fotowoltaiczne istnieje potencjał do zmiany bilansu energii i zwiększenia poziomu autokonsumpcji, a tym samym ograniczenia jego wpływu na pracę sieci nN. Jednakże, aby sterowanie takie było efektywne i przyjazne użytkownikowi, musi ono działać automatycznie. Oznacza to konieczność opracowania odpowiedniego systemu sterującego pracą różnorodnych urządzeń posiadanych przez odbiorców komunalno-bytowych. Taką funkcję realizuje system nazywany w literaturze anglojęzycznej Home Energy Management System (HEMS), będący głównym przedmiotem zainteresowania w niniejszej rozprawie doktorskiej.

System HEMS został stworzony, aby usprawnić zarządzanie energią w budynkach mieszkalnych, poprzez planowanie pracy i sterowanie pracą wielu urządzeń gospodarstwa domowego. Ogólną architekturę HEMS przedstawia rysunek 1.1. Jest to przykład typowej architektury HEMS [19], obejmującej instalację PV, różne urządzenia gospodarstwa domowego, magazyn energii elektrycznej (ang. Residential Energy Storage System – RESS), samochód elektryczny i centralny kontroler odpowiedzialny za zarządzanie pracą tych urządzeń. Urządzenia gospodarstwa domowego, których pracą ma zarządzać HEMS można podzielić na konwencjonalne, wymagające zastosowania tzw. inteligentnych wtyczek (ang. smart plugs) oraz sterowalne, potocznie nazwane „inteligentnymi” (ang. smart appliances). Kluczowym elementem systemu HEMS jest centralny kontroler, który odpowiada za optymalne zarządzanie zużyciem energii w gospodarstwie domowym. Komunikacja między

urządzeniami odbywa się za pomocą systemów przewodowych i bezprzewodowych. Interfejs człowiek-maszyna (ang. human-machine interface – HMI) prezentuje dane zebrane przez kontroler, pochodzące z inteligentnych liczników energii, różnorodnych czujników, inteligentnych wtyczek oraz pozostałych urządzeń zintegrowanych z HEMS. W ten sposób użytkownik otrzymuje pełną informację o przepływach energii elektrycznej w budynku.



Rys. 1.1 Ogólna architektura systemu HEMS (zaczepnięto z [Z.5])

2. TEZA, CEL I ZAKRES PRACY

Opisane w publikacji [Z.1] badania wstępne potwierdziły istnienie potencjału do optymalizacji pracy układu zasilania odbiorcy komunalno-bytowego wyposażonego w mikroinstalację fotowoltaiczną (prosumenta). W związku z tym postanowiono kontynuować tą tematykę badawczą w ramach wdrożeniowego projektu doktorskiego, dla którego sformułowano następującą tezę:

Zastosowanie u odbiorcy indywidualnego wyposażonego w źródło fotowoltaiczne systemu HEMS (Home Energy Management System), realizującego odpowiednio zaprojektowaną funkcję celu, umożliwia zwiększenie autokonsumpcji generowanej energii, a przez to zmniejszenie oddziaływania tego odbiorcy na system elektroenergetyczny.

Uwzględniając sformułowaną tezę przyjęto, że celem pracy jest opracowanie, praktyczna implementacja i przetestowanie w rzeczywistym środowisku metody kształtowania bilansu energii odbiorców komunalno-bytowych wyposażonych w mikroinstalacje fotowoltaiczne (prosumentów), prowadzącej do zwiększenia autokonsumpcji generowanej energii elektrycznej, dzięki odpowiedniemu sterowaniu zasobnikiem bateryjnym oraz odbiornikami o elastycznym czasie załączania i znanych profilach poboru energii.

Cel ten został osiągnięty w wyniku realizacji kolejnych etapów prac badawczo-wdrożeniowych obejmujących:

1. opracowanie metody prognozowania bazowego zapotrzebowania odbiorcy na energię elektryczną,
2. opracowanie metody prognozowania generacji energii elektrycznej w źródle fotowoltaicznym na podstawie numerycznej prognozy pogody,
3. opracowanie algorytmu optymalizującego pracę urządzeń zainstalowanych w badanym obiekcie, obejmujących bateryjny magazyn energii oraz odbiorniki o elastycznym czasie załączania,
4. budowę stanowiska badawczego umożliwiającą sterowanie magazynem i odbiornikami według harmonogramu wyznaczonego przez algorytm optymalizacyjny,
5. przeprowadzenie badań pozwalających na ocenę efektywności działania opracowanego algorytmu optymalizacyjnego oraz poprawności funkcjonowania wdrożonego systemu pomiarowo-sterującego w badanym obiekcie (w rzeczywistym budynku mieszkalnym).

Poszczególne etapy prac zostały krótko scharakteryzowane w kolejnych punktach autoreferatu, zgodnie z wymienionymi etapami prac badawczo-wdrożeniowych. Szczegółowy ich opis oraz szersza prezentacja uzyskanych wyników znajdują się w załączonych do autoreferatu artykułach (Załącznik [Z.1]), które wchodzi w skład powiązanych publikacji naukowych stanowiących rozprawę doktorską.

3. OPIS OSIĄGNIĘĆ NAUKOWYCH

3.1. Metoda prognozowania bazowego zapotrzebowania na energię elektryczną odbiorcy komunalno-bytowego

Opracowany system HEMS działa w horyzoncie dobowym. W związku z tym do opracowania planu pracy posiadanych przez odbiorcę komunalno-bytowego sterowanych odbiorników oraz magazynu energii konieczne jest dysponowanie dobową prognozą bazowego zapotrzebowania na energię elektryczną dla tego odbiorcy.

Dobowe profile zapotrzebowania indywidualnych odbiorców komunalno-bytowych charakteryzują się dużą zmiennością, a czynnikami mającymi wpływ na zróżnicowany pobór energii są m.in.: pora roku, dzień tygodnia oraz tryb życia i nawyki domowników. Zmienność obciążenia spowodowana jest głównie poprzez zróżnicowane czasowo załączanie różnych odbiorników, w tym również odbiorników, których czasem załączania można w pewnym stopniu sterować. W pracy doktorskiej uwagę skupiono na przygotowaniu prognozy zapotrzebowania bazowego odbiorcy komunalno-bytowego, czyli obciążenia wynikającego z pracy odbiorników podstawowych, tj. oświetlenia, lodówki, pomp obiegowych CO i C.W.U, komputerów, sprzętu RTV i AGD oraz innych odbiorników, których pracą nie będzie sterował system HEMS. Na tle wyznaczonej prognozy obciążenia bazowego ustalone zostaną następnie momenty załączenia odbiorników sterowanych, o elastycznym czasie załączania i znanym profilu poboru energii (wyznaczony zostanie również program pracy magazynu energii). Generalnie odbiorniki o sterowanym czasie załączania mogą obejmować m.in. pralkę, suszarkę do ubrań, zmywarkę, bojler elektryczny, elektryczne urządzenia grzewczo-chłodzące, ładowarki samochodów i rowerów elektrycznych, przy czym liczba i rodzaj tego typu odbiorników będzie się różnić w zależności od gospodarstwa domowego i będzie ustalana indywidualnie przez samych właścicieli budynku, w taki sposób, aby realizowane przez system HEMS użytkowanie tych urządzeń nie naruszało komfortu mieszkańców.


Opracowana metoda prognozowania bazowego zapotrzebowania odbiorcy na energię elektryczną została opisana szczegółowo w artykule [Z.4]. Opiera się ona na idei metody naiwnej i wykorzystuje historyczne dane pomiarowe z kilku takich samych dni poprzedzających. W pierwszym etapie prac zostały wykorzystane dane pomiarowe dotyczące zużycia energii pozyskane od dziesięciu przykładowych odbiorców komunalno-bytowych. Z ich zastosowaniem wyznaczano prognozę zapotrzebowania w różnych dniach. Zgodnie z założeniami metody naiwnej, prognoza opiera się na średnim zużyciu odbiorcy z pewnej liczby takich samych dni poprzedzających. Postanowiono jednak rozszerzyć tę ideę i oprócz

grafiku średniego do wyznaczenia prognozy zastosowano również inne metody opisu zmienności obciążenia, tj. grafik tzw. „typowy” oraz grafik statystycznie najczęstszy. Grafik „typowy” powstaje poprzez wyznaczenie wartości średnich z obciążeń uporządkowanych, które następnie zostają przypisane do odpowiednich przedziałów czasowych zgodnie z wyznaczonym wcześniej grafikiem średnim. Z kolei grafik statystycznie najczęstszy przedstawia wartości obciążeń, które wystąpiły najczęściej w poszczególnych przedziałach czasowych w analizowanych dniach poprzedzających. Sposoby tworzenia tych grafików opisano szczegółowo w artykule [Z.4]. Na podstawie przygotowanych grafików (średniego, „typowego” i statystycznie najczęstszego) wyznaczono prognozę obciążenia odbiorcy, będącą sumą ważoną poszczególnych grafików.

Kolejnym etapem pracy było przeprowadzenie badań mających na celu kalibrację i walidację opracowanego modelu prognostycznego. Prace nad kalibracją modelu zostały podzielone na dwie części. W pierwszej części, z grupy analizowanych dziesięciu odbiorców, wybrano pięciu, dla których wyszukana została optymalna liczba dni poprzedzających, przy przyjęciu jednakowych wartości wag poszczególnych składników prognozy. Najlepsze wyniki uzyskano w przypadkach, gdy liczba takich samych dni poprzedzających była równa 3, 4 lub 5. W drugiej części prac nad kalibracją modelu wyznaczono optymalne wartości współczynników wagowych. W tym celu zastosowano algorytm optymalizacji rojem cząstek (ang. Particle Swarm Optimization – PSO), dla którego funkcją celu było zminimalizowanie błędu MAPE. Analiza wyników wykazała, że dla dominującej liczby przypadków współczynnik wagowy dla grafiku średniego jest równy 1, a wartości współczynników wagowych dla grafiku „typowego” i statystycznie najczęstszego zawierają się zwykle w przedziale od -0,3 do 0,3 i mają taką samą wartość bezwzględną, ale przeciwne znaki. Następnie, po skalibrowaniu modelu, wykonana została jego walidacja, polegająca na wyznaczeniu prognoz zapotrzebowania dla wybranych dni dla pozostałych pięciu odbiorców. Uzyskane wyniki prognoz porównano z wynikami otrzymanymi przy zastosowaniu metody naiwnej w klasycznej postaci, w której prognoza zapotrzebowania w analizowanym dniu jest równa grafikowi średniemu z przyjętych dni poprzedzających. W większości przeanalizowanych przypadków błędy prognoz uzyskane za pomocą zaproponowanego modelu, w szczególności błąd MAPE, były niższe niż błędy uzyskane dla metody naiwnej.

W trzecim etapie badań opracowany model prognostyczny zastosowano do określenia bazowego zapotrzebowania odbiorcy komunalno-bytowego. Ocenę dokładności uzyskiwanych prognoz wykonano bazując na wynikach pomiarów zarejestrowanych przez dedykowany system pomiarowo-sterujący zainstalowany w budynku mieszkalnym. W artykule [Z.4] efekty

działania modelu prognostycznego w zastosowaniu do prognozowania bazowego obciążenia odbiorcy komunalno-bytowego zostały przedstawione na przykładzie prognoz wyznaczonych dla trzech kolejnych, takich samych dni roboczych. Uzyskane wyniki przedstawiono na rysunku 3.1 i w tabeli 3.1. Wskazują one, że maksymalna różnica pomiędzy dobowymi prognozowanymi, a rzeczywistymi wartościami bazowego zużycia energii analizowanego odbiorcy wyniosła około 10%, a błąd MAPE zawierał się w przedziale od 20 do 30%. Dzięki odpowiedniej kalibracji modelu uzyskano dokładność prognoz porównywalną z innymi, opisanymi w literaturze, bardziej zaawansowanymi modelami prognostycznymi, a prostota opracowanego modelu prognostycznego sprawia, że jest on możliwy do zastosowania w systemie HEMS zarządzającym energią w budynku mieszkalnym.



Rys. 3.1. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę: (a) 3 lipca 2024 r., (b) 10 lipca 2024 r., (c) 17 lipca 2024 r. (zaczepnięto z [Z.4])

Tabela 3.1


Rzeczywiste i prognozowane bazowe zużycie energii oraz błędy prognoz obciążenia bazowego odbiorcy komunalno-bytowego uzyskane przy zastosowaniu opracowanego modelu prognostycznego (zaczepnięto z [Z.4])

Dzień prognozy	Liczba dni poprzedzających	Bazowe zużycie energii		Błędy prognozy		
		rzeczywiste kWh	prognozowane kWh	MAE kWh	RMSE kWh	MAPE %
03.04	3	11,79	10,92	0,13	0,18	25,34
	4		10,87	0,14	0,21	24,89
	5		10,84	0,12	0,19	22,30
10.07	3	12,49	11,89	0,11	0,16	23,00
	4		11,18	0,11	0,15	20,73
	5		10,88	0,10	0,14	18,14
17.07	3	12,39	12,36	0,16	0,24	29,80
	4		11,88	0,15	0,23	27,19
	5		11,29	0,16	0,25	27,25

3.2. Metoda prognozowania generacji energii elektrycznej w źródle fotowoltaicznym na podstawie numerycznej prognozy pogody


Drugim niezbędnym elementem w pracy systemu HEMS jest prognozowany profil generacji energii w mikroinstalacji fotowoltaicznej, ponieważ posiadając te dane, a także prognozowany profil bazowego obciążenia odbiorcy, możliwe jest zaplanowanie pracy urządzeń w badanym obiekcie w taki sposób, aby m.in. zwiększyć poziom autokonsumpcji generowanej energii. Uwzględniając dodatkowo prognozowany profil cen energii elektrycznej możliwe jest opracowanie planu pracy tych urządzeń w sposób realizujący przyjętą (np. kosztową) funkcję celu, co zostanie omówione w następnym punkcie autoreferatu.

Na moc generowaną przez moduł fotowoltaiczny ma wpływ wiele czynników. Do najważniejszych z nich zalicza się m.in.: położenie geograficzne instalacji, kąt nachylenia, azymut, czystość powierzchni panelu i rodzaj materiału z jakiego zostały wykonane. Kolejnymi czynnikami są zmienność natężenia promieniowania słonecznego oraz temperatury modułu PV, ponieważ wraz ze wzrostem temperatury oraz wraz ze zmniejszeniem natężenia promieniowania słonecznego docierającego do panelu maleje wartość mocy jaką panel może wygenerować. Przykładowe charakterystyki zaprezentowane na rys. 3.2 przedstawiają wpływ ww. parametrów na moc wyjściową panelu. Przedstawione wykresy można odnaleźć w karatach katalogowych producentów paneli.



Rys. 3.2. Charakterystyki panelu fotowoltaicznego (zaczepnięto z [24]): (a) prądowo-napięciowa (w zależności od temperatury modułu), (b) mocowo-napięciowa (w zależności od natężenia promieniowania słonecznego), (c) prądowo-napięciowa (w zależności od natężenia promieniowania słonecznego)

Wpływ natężenia promieniowania słonecznego oraz temperatury panelu na wartość mocy generowanej uwzględniony został w wykorzystanym modelu źródła fotowoltaicznego, przedstawionym na rys. 3.3. Model ten wchodzi w skład oprogramowania OpenDSS [21].



Rys. 3.3. Model źródła PV używany przez program OpenDSS (zaczepnięto z [7])

Model źródła PV dostępny w programie OpenDSS składa się z modeli panelu fotowoltaicznego oraz falownika (inwertera). Głównym parametrem modelu panelu PV jest jego moc znamionowa P_{n_PV} , zdefiniowana dla standardowych warunków testowych (ang. Standard Test Conditions – STC), dla których temperatura ogniwa wynosi 25°C, a nasłonecznienie 1000 W/m². Obliczenie rzeczywistej mocy generowanej przez panel PV (P_{DC}) wymaga dostarczenia danych dotyczących aktualnego natężenia promieniowania

słonecznego i temperatury panelu oraz zdefiniowania jego charakterystyki mocowo-temperaturowej ($P = f(T)$), określonej przez producenta urządzenia. W procesie prognozowania generacji PV, natężenie promieniowania słonecznego pochodzi z numerycznej prognozy pogody, natomiast temperatura panelu jest obliczana z wykorzystaniem zewnętrznego modelu, który wykorzystuje dane dotyczące prognozy natężenia promieniowania słonecznego, temperatury otoczenia oraz prędkości wiatru. Szczegóły dotyczące sposobu wyznaczenia temperatury panelu przedstawiono w dalszej części autoreferatu.

Drugim elementem modelu jest model falownika (inwertera), który oblicza moc wyjściową (po stronie AC) rozpatrywanej instalacji PV. Podstawowymi parametrami modelu falownika są napięcie znamionowe (U_n), moc znamionowa (S_n) i współczynnik mocy ($\cos\varphi$), a dane wejściowe stanowi obliczona w pierwszym etapie moc generowana przez panel fotowoltaiczny (P_{DC}). Dla modelu falownika definiuje się również charakterystykę obrazującą sprawność urządzenia w zależności od stopnia obciążenia ($\eta = f(P)$) oraz określa tryb pracy inwertera, który może działać w następujący sposób:

1. stały współczynnik mocy $\cos\varphi$ – inwerter dostarcza moc bierną w stałej proporcji do generowanej mocy czynnej,
2. sterowanie mocą bierną (tzw. tryb $U-Q$) – inwerter dostosowuje moc bierną w zależności od napięcia w punkcie przyłączenia, co pozwala na regulację napięcia w sieci dystrybucyjnej,
3. sterowanie mocą czynną (tzw. tryb $U-W$) – inwerter redukuje moc czynną w odpowiedzi na wzrost napięcia, aby zapobiec przekroczeniu dopuszczalnych wartości napięcia w sieci.


W procesie prognozowania generacji PV przyjęto pierwszy tryb pracy falownika i założono $\cos\varphi = 1$. Dla tak sparametryzowanego modelu, na podstawie wyznaczonej przez model panelu mocy P_{DC} oraz zdefiniowanej charakterystyki sprawności falownika $\eta = f(P)$, w procesie prognozowania generacji obliczana jest moc czynna (P) źródła PV do strony AC.

Jak wspomniano wyżej, celem prawidłowego obliczenia mocy generowanej przez panel PV (P_{DC}) konieczna jest znajomość jego temperatury. W procesie prognozowania generacji PV ta informacja musi zostać obliczona na podstawie prognozowanych warunków otoczenia, w których panel będzie pracował w analizowanym okresie. Do tego służą odpowiednie modele empiryczne.

Opracowanie metody krótkoterminowego prognozowania generacji energii elektrycznej w źródle fotowoltaicznym rozpoczęto od przeglądu dostępnych modeli empirycznych służących do szacowania temperatury modułów fotowoltaicznych w zależności od warunków

pogodowych. Zestawienie modeli zostało przedstawione w artykule [Z.2]. W następnym etapie przeprowadzono ocenę dokładności zebranych modeli z wykorzystaniem rzeczywistych danych pomiarowych. W tym celu wykorzystano historyczne dane pomiarowe dotyczące temperatury paneli PV pochodzące z instalacji fotowoltaicznej oraz dane pogodowe obejmujące natężenie promieniowania słonecznego, prędkość wiatru i temperaturę otoczenia, pochodzące ze stacji pogodowej zintegrowanej z tą instalacją PV. Do analizy porównawczej wybrano odnawialne źródło energii wraz z osprzętem pomiarowym, które znajduje się na dachu jednego z budynków Politechniki Śląskiej w Gliwicach.

Wykonana analiza modeli empirycznych wykazała, że otrzymane z ich wykorzystaniem wyniki cechowały się stosunkowo dużą dokładnością dla danych pomiarowych dostarczanych w rozdzielczości godzinowej, natomiast dla danych pomiarowych dostarczanych w rozdzielczości minutowej modele empiryczne charakteryzowały się ograniczoną dokładnością w określaniu temperatury modułu PV pracującego w zmiennych warunkach atmosferycznych. W niektórych przypadkach błąd oszacowania dla danych w rozdzielczości minutowej przekroczył 25°C (rys. 3.4), co przekłada się na około 10% błąd szacowania generacji PV. Tak wysoka wartość błędów modeli empirycznych wynika z głównej cechy przeanalizowanych modeli, którą jest pominięcie bezwładności cieplnej modułu PV.




Rys. 3.4. Temperatura modułu fotowoltaicznego obliczona przy użyciu różnych modeli empirycznych w porównaniu ze zmierzoną temperaturą — warunki atmosferyczne w rozdzielczości minutowej, dane z 24 maja 2020 r. (zaczepnięto z [Z.2])

Problem z pominięciem bezwładności cieplnej panelu PV w istniejących modelach empirycznych postanowiono rozwiązać poprzez opracowanie dynamicznego modelu cieplnego modułu fotowoltaicznego, opisanego szczegółowo w publikacji [Z.2]. Zaproponowany model wzorowany jest na modelu cieplnym transformatora olejowego i opiera się na metodzie różnic skończonych (ang. Finite Difference Method – FDM). Wykorzystuje on jedynie dane dotyczące temperatury otoczenia, nasłonecznienia i prędkości wiatru, a więc dane dostępne w numerycznych prognozach pogody. Dzięki zastosowaniu metody FDM, model ten uwzględnia w swoim równaniu bezwładność cieplną modułu fotowoltaicznego. Celem opracowania uogólnionego modelu cieplnego modułu PV, współczynniki opracowanego modelu zostały zoptymalizowane przy użyciu metody PSO. Weryfikacja opracowanego modelu została wykonana na podstawie danych pomiarowych pochodzących z wyżej wymienionej instalacji fotowoltaicznej Politechniki Śląskiej. Uzyskane wyniki wskazywały na znaczącą poprawę dokładności szacowania temperatury modułu fotowoltaicznego (maksymalny błąd oszacowania temperatury zmniejszył się z 25°C do 9°C).


Celem pogłębionej oceny dokładności opracowanego modelu postanowiono również zweryfikować poprawność szacowania temperatury panelu porównując go z podobnym modelem i wykorzystując dane pomiarowe pochodzące z innego źródła. Porównano wyniki szacowania temperatury uzyskane przez opracowany model z wynikami uzyskanymi przy zastosowaniu dynamicznego modelu cieplnego panelu PV zaproponowanego przez Barry'ego i in. [20]. Wykorzystano dane pomiarowe z systemów zlokalizowanych w regionie Allgäu w Niemczech. Porównanie wyników (rys. 3.5) ponownie potwierdziło wysoką skuteczność zaproponowanego modelu w zastosowaniu do obliczania temperatury modułu fotowoltaicznego pracującego w zmiennych warunkach pogodowych.

Posiadając zweryfikowany na rzeczywistych danych pomiarowych model cieplny panelu PV przystąpiono do drugiego etapu prac związanych z opracowaniem metody krótkoterminowego prognozowania generacji źródła PV z zastosowaniem opisanego wcześniej modelu źródła PV. W tym celu również wykorzystano dane pomiarowe dotyczące generacji źródła PV pochodzące z wyżej wymienionej instalacji PV Politechniki Śląskiej oraz historyczne numeryczne prognozy pogody, pochodzące z dwóch ogólnodostępnych platform meteorologicznych. Dane pogodowe zostały pozyskane w rozdzielczości godzinowej dla platform A i B oraz pięciominutowej dla platformy B. Dane dotyczące rzeczywistej generacji źródła PV miały analogiczną rozdzielczość.



Rys. 3.5. Temperatura modułu fotowoltaicznego obliczona przy użyciu uogólnionej formy modelu różnic skończonych i dynamicznego modelu Barry'ego i in. w porównaniu z temperaturą zmierzoną — warunki atmosferyczne w rozdzielczości minutowej, dane z 14 września 2018 r. (zaczepnięto z [Z.2])

Pierwszym krokiem obliczeniowym było przygotowanie danych wejściowych do modelu źródła PV w programie OpenDSS. Zgodnie z opisem przedstawionym wyżej dane te obejmowały natężenie promieniowania słonecznego (wykorzystane jako dane wejściowe do modelu źródła PV oraz modelu cieplnego panelu) oraz informacje o temperaturze otoczenia i prędkości wiatru (wykorzystane jako dane wejściowe do modelu cieplnego panelu PV). Do badań zostały wybrane dwa losowe dni, dla których zostały wykonane symulacje z wykorzystaniem danych numerycznych prognoz pogody w rozdzielczości godzinowej i pięciominutowej. Analiza przeprowadzonych symulacji wykazała, że najlepsze wyniki uzyskano dla prognozy w rozdzielczości pięciominutowej z platformy B. Różnica w dobowej ilości wygenerowanej energii pomiędzy wartością obliczoną, a zmierzoną w najlepszym przypadku wyniosła 3,6%, natomiast błąd MAPE nie przekroczył 27%. Uzyskane wyniki przedstawiono na rysunku 3.6 i w tabeli 3.2.



Rys. 3.6. Prognoza generacji fotowoltaicznej na podstawie prognozy pogody w rozdzielczości godzinowej dla platform A oraz B oraz 5 min dla platformy B w porównaniu z mocą zmierzoną dla (a) 27 czerwca 2021 r., (b) 29 września 2021 r., (zaczepnięto z [Z.3])

Tabela. 3.2.

Prognoza dziennej produkcji energii i błędy MAPE (zaczepnięto z [Z.2])

Dzień prognozy	Platforma, rozdzielczość	Dzienna produkcja energii			Błąd MAPE
		Zmierzona	Obliczona	Różnica	
		kWh	kWh	%	
27.06	A, 1 h	98,6	124,5	26,3	87,1
	B, 1 h		118,3	20,1	59,7
	B, 5 min		114,2	15,9	53,4
29.09	A, 1 h	38,5	72,0	86,9	124,7
	B, 1 h		40,3	4,6	28,5
	B, 5 min		39,9	3,6	26,5

Postanowiono również przetestować opracowaną metodę prognozowania generacji w rzeczywistych mikroinstalacjach prosumenckich. Do badań wybrano dwie instalacje PV. Pierwsza z badanych instalacji o mocy znamionowej 7,32 kW znajdowała się w Koszęcinie (woj. Śląskie), a druga, o mocy 6,1 kW, zlokalizowana była w Łączy (woj. Śląskie). Dla obu lokalizacji zastosowano numeryczne prognozy pogody w rozdzielczości pięciominutowej. Uzyskane wyniki przedstawiono w tabelach 3.3 oraz 3.4. oraz na rysunku 3.7.

Tabela. 3.3.


Prognoza dziennej produkcji energii i błędy MAPE dla instalacji prosumenckiej 7,32 kW (zaczepnięto z [Z.3])

Dzień prognozy	Dzienna produkcja energii			Błąd MAPE
	Zmierzona	Obliczona	Różnica	
	kWh	kWh	%	
10.06	28,4	26,5	-6,8	43,1

Tabela. 3.4.

Prognoza dziennej produkcji energii i błędy MAPE dla instalacji prosumenckiej 6,1 kW (zaczepnięto z [Z.3])

Dzień prognozy	Dzienna produkcja energii			Błąd MAPE
	Zmierzona	Obliczona	Różnica	
	kWh	kWh	%	
16.06	23,9	30,8	28,7	70,0



Rys. 3.7. Prognoza generacji fotowoltaicznej wyznaczona na podstawie numerycznej prognozy pogody dla platformy B (rozdzielczość 5 min.) w porównaniu z mocą zmierzona dla: (a) mikroinstalacja PV o mocy 7,32 kW w Koszęcinie, 10 czerwca 2022 r., (b) mikroinstalacja PV o mocy 6,1 kW w Łączy, 16 czerwca 2022 r., (zaczepnięto z [Z.3])

Analiza uzyskanych wyników wykazała, że prognozy generacji PV obliczone dla numerycznych prognoz pogody dostarczanych w wyższej rozdzielczości czasowej charakteryzują się lepszą dokładnością. Szczegółowe wyniki badań dotyczących

krótkoterminowego prognozowania generacji PV przedstawiono w publikacji [Z.3]. Opracowana metoda prognozowania generacji energii w źródle fotowoltaicznym bazuje jedynie na trzech składnikach numerycznych prognoz pogody i dzięki swojej prostocie jest możliwa do zastosowania w systemie HEMS. Przy implementacji tej metody w systemie sterującym w budynku należy zwrócić uwagę na platformę, która udostępnia numeryczne prognozy pogody. Szczególną uwagę należy zwrócić na lokalizację, dla której podawana jest prognoza, aby była ona jak najbliżej miejsca zainstalowania rozpatrywanej instalacji PV.

3.3. Algorytm optymalizujący pracę urządzeń elektrycznych zainstalowanych u odbiorcy komunalno-bytowego

W ostatnich latach technologia wytwarzania energii w źródłach fotowoltaicznych stanowi główny segment w wytwarzaniu energii ze źródeł odnawialnych na świecie [25]. W Polsce rozwój tego segmentu jest szczególnie napędzany przez systemy prosumenckie o mocy zainstalowanej poniżej 50 kW. Największy udział w 2024 roku stanowiły mikroinstalacje, montowane zazwyczaj na dachach budynków. Większość mikroinstalacji w Polsce (prawie 98,6%) należała do prosumentów, których w całym kraju było 1 522 655. Mikroinstalacje te odpowiadały niemal za 95 procent mocy zainstalowanej – 12 045 MW [26]. Przeważająca liczba mikroinstalacji PV jest instalowana w celu zużywania generowanej energii na pokrycie bieżącego zapotrzebowania, jednak często moce tych źródeł są przewymiarowane względem faktycznego zużycia energii przez prosumenta. Ponadto zwykle profile obciążenia i generacji są rozbieżne [27]. Powoduje to oddawanie nadmiaru generowanej energii do sieci dystrybucyjnej, co wpływa negatywnie na jej działanie [28]. Zatem prężnie rozwijający się segment prosumenckich instalacji PV wymaga stworzenia prostego, skalowalnego rozwiązania umożliwiającego automatyczne zarządzanie energią, które można by szeroko zastosować w budynkach mieszkalnych, aby jeszcze szerzej rozpowszechnić ideę wykorzystania energii odnawialnej opartej na źródłach fotowoltaicznych i jednocześnie zminimalizować negatywny wpływ tych źródeł na sieć elektroenergetyczną.

Koncepcja rozwiązania dotyczącego zarządzania popytem w systemach energetycznych (ang. Demand Side Management – DSM) pojawiła się w latach 70. XX wieku w USA podczas kryzysu naftowego. Celem tego rozwiązania było zmniejszenie zużycia energii w godzinach szczytowego zapotrzebowania, aby uniknąć rozbudowy systemu elektroenergetycznego. Rozwijane od tego czasu systemy DSM stanowią ważny element w historii rozwoju systemów HEMS, a pierwsza koncepcja systemu automatyki domowej pojawiła się w latach 90-tych XX

wieku [29]. Jej głównym założeniem było wykorzystanie automatyki domowej w sektorze mieszkaniowym, celem umożliwienia odbiorcom energii uczestniczenia w programach DSM poprzez automatyczne dostosowanie ich zużycia do potrzeb systemu elektroenergetycznego. Dalszy rozwój systemów HEMS, w formie jaka jest obecnie znana, nastąpił po roku 2010, ponieważ wtedy popularność zyskały elementy systemu Internetu rzeczy (ang. – Internet of Things – IoT), czyli systemy automatyki budynkowej, które umożliwiają m.in. sterowanie odbiornikami. W tym samym czasie do użytku zaczęły wchodzić domowe magazyny energii (ang. Residential Energy Storage Systems – RESS), które znacząco poszerzyły możliwość zarządzania bilansem energii w budynku mieszkalnym. Tak szeroki potencjał kształtowania popytu, połączony z coraz popularniejszym wykorzystaniem mikroinstalacji PV zintegrowanych z budynkami mieszkalnymi, stanowi jeden z czynników stymulujących obecnie rozwój systemów HEMS.

Systemy HEMS można podzielić na dwa główne rodzaje: oparte na regułach logicznych (ang. rule-based HEMS) i oparte na metodach optymalizacji (ang. optimization-based HEMS) [30]. Celem algorytmu, według którego działa system HEMS oparty na regułach jest najczęściej minimalizacja wymiany energii z siecią elektroenergetyczną. Oznacza to, że w tym przypadku budynek działa jako klient, który aktywnie stara się unikać dostarczania energii elektrycznej generowanej w mikroinstalacji PV do sieci rozdzielczej i robi to tylko wtedy, gdy to się nie powiedzie. Systemy HEMS bazujące na regułach logicznych są zwykle zaimplementowane w fabrycznych sterownikach dostarczanych przez producentów magazynów energii. Główną wadą tych systemów jest to, że sterując magazynem w sposób minimalizujący wymianę energii z siecią nie uwzględniają one bilansu całodobowego, a jedynie chwilowy. Oznacza to, że przy korzystnych warunkach pogodowych (duże nasłonecznienie) magazyn energii może zostać całkowicie naładowany już w godzinach porannych, podczas gdy lepszy efekt (np. w postaci większej redukcji niekorzystnego oddziaływania mikroinstalacji na sieć nN) można by osiągnąć, gdyby magazyn ładowany był dopiero w godzinach okołopołudniowych, czyli w czasie, w którym najczęściej występują problemy z przekroczeniem dopuszczalnej wartości napięcia. Dodatkowo systemy HEMS oparte na regułach dostarczane przez producentów magazynów zwykle nie posiadają możliwości sterowania wybranymi odbiornikami. W związku z powyższym w ramach realizacji niniejszej pracy postanowiono przeanalizować możliwość wykorzystania drugiego rozwiązania, czyli systemów HEMS opartych na metodach optymalizacji.

W systemach HEMS opartych na metodach optymalizacji podejście do sterowania magazynem energii różni się od tego opartego na regułach logicznych, ponieważ zadawane

mogą być w nich różne funkcje celu algorytmu optymalizującego, skutkujące różnymi programami pracy magazynu. Ponadto projektant tego typu system HEMS ma możliwość uwzględnienia również optymalizacji pracy odbiorników o sterowanym czasie załączania i znanym profilu poboru energii (ang. Shiftable Loads – SL). Horyzont optymalizacji zwykle obejmuje kolejną dobę, a obliczenia wykonywane są w rozdzielczości godzinowej. Najczęściej stosowaną funkcją celu jest minimalizacja dobowego kosztu energii elektrycznej w analizowanym budynku, określona zależnością:

$$f = \sum_{h=1}^{24} c_h P_{EX,h}, \quad (3.1)$$

w której c_h jest ceną energii w godzinie h , a $P_{EX,h}$ oznacza wymianę energii między budynkiem a siecią w godzinie h (użyto symbolu P , ponieważ analizowane są przedziały godzinowe ze stałą wartością mocy w tym czasie, a więc moc godzinowa jest równa energii). Wartość wymiany energii z siecią w godzinie h można obliczyć za pomocą następującego wzoru:

$$P_{EX,h} = P_{FIX,h} + P_{SHIFT,h} - P_{PV,h} - P_{RESS,h} \quad (3.2)$$

gdzie $P_{FIX,h}$, $P_{SHIFT,h}$ oznaczają odpowiednio stałe (niesterowalne) oraz zmienne (sterowalne) obciążenie odbiorcy w godzinie h , $P_{PV,h}$ jest generacją źródła PV, a $P_{RESS,h}$ definiuje punkt pracy magazynu energii w godzinie h . Zadając punkt pracy magazynu energii RESS (znak dodatni oznacza rozładowanie, a znak ujemny ładowanie akumulatora) i ustawiając czas załączania sterowalnych odbiorników SL o znanych profilach poboru energii, możliwe jest uzyskanie pożądanej wartości wymiany energii z siecią w poszczególnych godzinach, a w efekcie – przy zadanych cenach energii – zmiana wartości optymalizowanej funkcji celu.


Zastosowanie minimalizacji kosztu energii (3.1), jako funkcji celu w systemie HEMS, w naturalny sposób będzie skutkowało chęcią uzyskania przez prosumenta jak największych korzyści finansowych, czyli zarabiania na wyprodukowanej w źródle PV energii. Takie podejście stoi jednak w sprzeczności z ideą prosumenta energii odnawialnej, który z założenia produkuje ją w przeznaczeniu do zaspokojenia własnych potrzeb. W związku z tym w artykule [Z.5] zaproponowano inną funkcję celu, którą jest maksymalizacja dobowej neutralności finansowej prosumenta, uzyskiwana przez minimalizację wartości funkcji określonej wzorem:

$$f = \sqrt{\sum_{h=1}^{24} (c_h P_{EX,h})^2}. \quad (3.3)$$

Ceny energii wykorzystane w zależności (3.3) mogą być stałe w ciągu doby (np. ceny taryfowe) lub mogą zmieniać się w kolejnych interwałach czasowych (tzw. dynamiczne ceny energii). W ramach prowadzonych prac zastosowano dynamiczne ceny energii, zmieniające się w cyklu godzinowym. Ponieważ dynamiczne ceny energii mogą przyjmować wartości dodatnie i ujemne oraz wymiana energii z siecią również może być dodatnia (import energii z sieci) lub ujemna (eksport energii do sieci), to w efekcie w poszczególnych godzinach prosument może zarówno ponosić koszt, jak i uzyskiwać przychód. Poprzez podniesienie iloczynów ceny energii elektrycznej i wymiany energii z siecią do kwadratu, w procesie minimalizacji funkcji (3.3), zarówno koszt, jak i przychód prosumenta są minimalizowane. W ten sposób neutralność finansowa prosumenta zostaje zmaksymalizowana. Zastosowanie pierwiastka kwadratowego zapewnia lepszą zbieżność algorytmu optymalizacji oraz umożliwia bezpośrednie porównanie wartości funkcji celu (3.1) i (3.3). Przedstawiona funkcja celu (3.3) jest zgodna z ideą prosumenta energii odnawialnej, który ma przede wszystkim wytwarzać energię na własne potrzeby.

Systemy HEMS oparte na metodach optymalizacji eliminują wymienione wyżej niedoskonałości systemów opartych na regułach. W ramach wykonanych badań, opisanych szczegółowo w artykule [Z.5], porównano działanie systemu HEMS wykorzystującego funkcję celu (3.3) z systemem HEMS opartym na regułach logicznych (zaimplementowanym fabrycznie w sterowniku magazynu energii). W celu oceny efektów uzyskiwanych przez zaproponowany system HEMS wykorzystano dane pomiarowe z rzeczywistej instalacji budynku jednorodzinnej. Obiekt ten wyposażony jest w mikroinstalację PV o mocy 5,25 kW oraz akumulator RESS o mocy 5 kW i pojemności 20,8 kWh, z ustawieniami minimalnego i maksymalnego poziomu naładowania (odpowiednio 10% i 100%). Wyniki pomiarów dla dwóch wybranych dni przedstawiono na rysunkach 3.8.a i 3.8.b. Na rysunkach tych widoczna jest generacja PV i praca magazynu energii sterowanego za pomocą systemu HEMS opartego na regułach. Na tle całkowitego obciążenia budynku, zaznaczono również pracę odbiorników o sterowanym czasie załączania i znanym profilu poboru energii (pralka, zmywarka – zielone prostokąty). Należy jednak zaznaczyć, że podczas pomiarów odbiory te nie podlegały sterowaniu (zaimplementowany w sterowniku magazynu energii system HEMS oparty na regułach logicznych nie posiada takiej funkcjonalności). Porównując przedstawione na rys. 3.8 wyniki pomiarów można zauważyć, że wybrane do badań dni 20 oraz 21 września charakteryzowały się podobnymi profilami obciążenia oraz generacji energii w źródle PV. W obu tych dniach praca magazynu energii, sterowanego według fabrycznie


zaimplementowanego algorytmu opartego na regułach logicznych, była również podobna (około południa magazyn został w pełni naładowany). W efekcie zarejestrowane profile wymiany energii z siecią były również do siebie zbliżone (następował eksport energii do sieci w okresach wysokiej generacji PV).



Rys. 3.8. Zmierzone profile obrazujące: pracę źródła PV i magazynu energii RESS oraz sumaryczne obciążenie budynku (zielonymi prostokątami zaznaczono pracę odbiorników sterowalnych SL) i wymianę energii z siecią (a) w dniu 20 września. 2023 r. i (b) 21 września 2023 r. (zaczepnięto z [Z.5])


Zarejestrowane dane pomiarowe dla obu wybranych dni (rys. 3.8) stanowią bazę porównawczą dla wyników symulacji działania systemu HEMS bazującego na metodzie optymalizacji (zastosowano algorytm Particle Swarm Optimization – PSO, realizujący funkcję celu (3.3) [Z.5]). Symulacje działania systemu HEMS maksymalizującego neutralność finansową prosumenta przeprowadzono w dwóch wariantach obliczeniowych. W pierwszym wariantcie optymalizowano tylko dobowy profil pracy magazynu energii RESS, natomiast w drugim wariantcie optymalizowano zarówno pracę RESS, jak i czas załączania sterowanych odbiorników SL o znanym profilu poboru energii (zielone prostokąty na rys. 3.8). Dynamiczne ceny energii elektrycznej, występujące we wzorze (3.3), pochodzą ze strony Polskich Sieci Elektroenergetycznych. Przedstawia je rys. 3.9. Należy zauważyć, że wybrane do analizy dni

znacząco różniły się od siebie cenami energii elektrycznej. Profil cenowy z 21 września miał typowy kształt, ze stabilnymi cenami w ciągu dnia i wyższymi cenami w wieczornym szczycie zapotrzebowania. Z kolei profil cenowy z 20 września charakteryzował się znacznym spadkiem cen energii między godzinami 9:00 a 14:00, z ujemnymi cenami od 10:00 do 13:00, co było wynikiem wysokiej produkcji energii ze źródeł odnawialnych, w szczególności fotowoltaicznych, w tym czasie [31]. Występujące różnice w profilach cenowych dla obu analizowanych dni znacząco wpływają na uzyskane profile pracy magazynu energii oraz czas załączania sterowanych odbiorników.




Rys. 3.9. Godzinowe ceny rynkowe energii elektrycznej w dniach 20 września i 21 września 2023 r. wykorzystane w symulacjach (zaczepnięto z [Z.5])

Porównanie wyników przeprowadzonych symulacji pracy systemu HEMS opartego na metodzie optymalizacji z wynikami pomiarów uzyskanymi dla systemu HEMS opartego na regułach logicznych przedstawiono na rysunkach 3.10 i 3.11. Na rys. 3.10 zilustrowano profile pracy magazynu energii RESS (wartości ujemne oznaczają ładowanie, a dodatnie rozładowanie magazynu), natomiast na rys. 3.11, na tle całkowitego obciążenia budynku, zaznaczono okresy pracy sterowanych odbiorników SL (przy sterowaniu RESS i SL opartym na optymalizacji widoczne jest przeniesienie pracy odbiorników SL z godzin późno popołudniowych na godziny południowe, czyli na okresy najwyższej generacji PV).



Rys. 3.10. Dobowe profile pracy RESS wynikające ze sterowania za pomocą metody opartej na regułach oraz metody opartej na optymalizacji: (a) w dniu 20 września 2023 r., (b) w dniu 21 września 2023 (zaczepnięto z [Z.5])



Rys. 3.11. Praca odbiorników o sterowanym czasie załączania SL wynikająca ze sterowania za pomocą metody opartej na regułach oraz metody opartej na optymalizacji: (a) w dniu 20 września 2023 r., (b) w dniu 21 września 2023 (zaczepnięto z [Z.5])

Profile pracy RESS (rys. 3.10) obrazują sposobyysterowania magazynu energii przez algorytmy zarządzające w obu analizowanych dniach. W dniu 20 września, algorytm RESS oparty na optymalizacji od północy do godziny 9.00 rano oraz w godzinach wieczorno-nocnych wyznaczył podobny profil pracy w porównaniu do sterowania opartego na regułach (rys. 3.10.a). Z kolei różnice w działaniu RESS sterowanym wg analizowanych sposobów uwidoczniły się w godzinach od 9.00 do 15.00, czyli głównie podczas obowiązywania niskich cen energii elektrycznej w badanym dniu. W tym okresie algorytm oparty na optymalizacji PSO wyznaczył niższą moc ładowania magazynu niż wynikało to ze sterowania opartego na regułach, co wydłużyło czas ładowania magazynu. W ten sposób praca RESS była lepiej dostosowana do profilu generacji źródła fotowoltaicznego w tym dniu.


W dniu 21 września różnice w wyznaczonych profilach pracy magazynu były widoczne już w nocy. W tym okresie algorytm optymalizacyjny PSO wyznaczył plan pracy RESS w taki sposób, żeby rozładowywał się on z mocą większą niż wynikało to z zapotrzebowania budynku. W ten sposób algorytm optymalizacyjny lepiej przygotował magazyn energii do trybu ładowania w ciągu dnia, co jest zauważalne na rysunku 3.10.b w godzinach południowych, czyli przy największej generacji PV, a zarazem w okresie obowiązywania najniższych cen energii. Dla obydwóch analizowanych dni widoczny jest również wpływ przeniesienia obciążenia sterowanego (SL) z godzin wieczornych na inne godziny doby (rys.3.11). W godzinach, w których zapotrzebowanie na energię w budynku wzrosło w wyniku przeniesienia obciążenia SL, magazyn był ładowany z mniejszą mocą, a zaoszczędzona w ten sposób pojemność została wykorzystana w innym czasie.

Wyznaczone za pomocą metody sterowania bazującej na optymalizacji profile pracy RESS oraz okresy pracy SL wpływają na zmianę profili wymiany energii z siecią elektroenergetyczną nN, w stosunku do profili zmierzonych, uzyskanych przy zastosowaniu sterowania RESS bazującego na regułach logicznych. Tę kwestię zilustrowano na rys. 3.12 (wartości ujemne symbolizują eksport energii do sieci, a dodatnie import energii z sieci). Zaprezentowane rezultaty symulacji pokazują, że zastosowanie algorytmu optymalizacyjnego PSO w systemie zarządzania energią HEMS przyniosło wymierne efekty w postaci redukcji eksportu energii elektrycznej do sieci elektroenergetycznej, co miało istotne znaczenie ekonomiczne dla prosumenta, szczególnie w kontekście dynamicznych i niekorzystnych dla niego (niskich lub nawet ujemnych) cen energii.

W dniu 20 września (rys. 3.10.a) eksport energii do sieci występował przez pięć godzin, obejmując okres od 9:00 do 14:00, przy czym w godzinach szczytowej generacji PV odnotowano wyraźny spadek ilości energii oddawanej do sieci, co wiązało się z dynamicznie

zmieniającymi się cenami energii elektrycznej w ciągu dnia. Ceny te w godzinach 9:00–10:00 oraz 13:00–14:00 były dodatnie i wynosiły 0,01 PLN/kWh, jednak już w godzinach 10:00–11:00 i 12:00–13:00 ceny spadły do poziomu –0,01 PLN/kWh, a w godzinie od 11:00 do 12:00 osiągnęły wartość –0,02 PLN/kWh (rys. 3.9). Oznacza to, że w okresie od 10:00 do 13:00 eksport energii był dla prosumenta całkowicie nieopłacalny (gdyby do rozliczenia zastosowano wprost ceny dynamiczne, to prosument musiał ponosić opłatę za oddaną do sieci energię). W odpowiedzi na tę niekorzystną sytuację ekonomiczną, zastosowany w systemie HEMS algorytm PSO zoptymalizował pracę magazynu energii RESS (oraz czas załączenia odbiornika SL), ograniczając wymianę z siecią w godzinach z ujemnymi cenami energii. Pozwoliło to na minimalizację strat finansowych poprzez magazynowanie nadwyżki energii. Efektem było zmniejszenie dziennego eksportu energii z 7,6 kWh do 6,6 kWh. Dodatkowo, wprowadzenie mechanizmów zarządzania popytem DSM (przesunięcie okresu pracy odbiornika SL) umożliwiło dalsze ograniczenie eksportu do poziomu 5,6 kWh. Jeszcze większe korzyści w postaci zmniejszenia eksportu energii do sieci odnotowano w dniu 21 września (rys. 3.10.b), kiedy to, dzięki zastosowaniu optymalizacji PSO, eksport został zmniejszony z początkowych 11,8 kWh (przy sterowaniu opartym na regułach) do 7,9 kWh w pierwszym wariantcie optymalizacji (sterowanie RESS) i do 7,8 kWh w drugim wariantcie (sterowanie RESS i SL). To pokazuje, że elastyczne zarządzanie energią w oparciu o zmienne ceny rynkowe może w znaczący sposób wpłynąć na zwiększenie efektywności energetycznej i ekonomicznej systemów prosumenckich.

Podsumowując, dynamiczne ceny energii (zarówno dodatnie, jak i ujemne) stanowią skuteczne narzędzie wpływające na sposób pracy prosumenckich systemów zasilania budynku, wykorzystujących mikroinstalacje PV. W połączeniu z inteligentnym systemem zarządzania opartym na algorytmach optymalizacyjnych, możliwe jest nie tylko ograniczenie kosztów, ale także bardziej zrównoważone i efektywne wykorzystanie dostępnych zasobów energii oraz zmniejszenie wpływu tego typu obiektów na pracę sieci rozdzielczej nN. Syntetyczne podsumowanie wykonanych dla obu rozpatrywanych dni analiz zawierają tabele 3.5 i 3.6.



Rys. 3.12. Wymiana z siecią wynikająca ze zmierzonego (opartego na regułach) i zoptymalizowanego metodą PSO działania RESS i SL (a) w dniu 20 września 2023 r. i (b) w dniu 21 września 2023 r. (zaczepnięto z [Z.5])

Tabela. 3.5.

Najważniejsze wielkości charakteryzujące pracę analizowanego systemu zasilania budynku mieszkalnego w dniu 20 września 2023 r. dla różnych wariantów działania systemu HEMS

Działanie systemu HEMS:	Generacja źródła PV	Obciążenie	Magazyn energii (RESS)		Wymiana z siecią		Autokonsumpcja	Koszt
			Ładowanie	Rozładowanie	Pobór	Oddanie		
	kWh	kWh	kWh	kWh	kWh	kWh	%	PLN
Oparte na regułach (pomiar)	26,0	9,3	14,8	5,1	0,6	7,6	43,1	-0,65
Oparte na optymalizacji (tylko RESS)	26,0	9,3	15,7	5,6	0	6,6	46,9	0
Oparte na optymalizacji (RESS i SL)	26,0	9,3	15,7	4,6	0	5,6	48,0	0

Tabela. 3.6.

Najważniejsze wielkości charakteryzujące pracę analizowanego systemu zasilania budynku mieszkalnego w dniu 21 września 2023 r. dla różnych wariantów działania systemu HEMS

Działanie systemu HEMS:	Generacja źródła PV	Obciążenie	Magazyn energii (RESS)		Wymiana z siecią		Autokonsumpcja	Koszt
			Ładowanie	Rozładowanie	Pobór	Oddanie		
	kWh	kWh	kWh	kWh	kWh	kWh	%	PLN
Oparte na regułach (pomiary)	22,5	9,1	7,2	5,1	0,6	11,8	36,7	-5,12
Oparte na optymalizacji (tylko RESS)	22,5	9,1	12,2	6,8	0	7,9	41,8	-3,84
Oparte na optymalizacji (RESS i SL)	22,5	9,1	14,5	9,0	0	7,8	48,5	-3,64

Wyniki przeprowadzonych symulacji wykazały wzrost autokonsumpcji (zużycia własnego) wyprodukowanej energii PV w przypadku zastosowania sterowania RESS za pomocą systemu HEMS opartego na algorytmie optymalizacyjnym, w stosunku do sytuacji, w której magazyn sterowany był fabrycznym algorytmem opartym na regułach logicznych. Dla metody optymalizacji PSO zastosowanej do sterowania tylko magazynem energii RESS całkowite dzienne zużycie własne wzrosło z 43,1% do 46,9% w pierwszym analizowanym dniu i z 36,7% do 41,8% w drugim dniu. Jeszcze większy wzrost autokonsumpcji odnotowano po łącznej optymalizacji pracy magazynu energii RESS i odbiorników sterowanych SL. W tym przypadku zużycie własne wzrosło do 48,0% pierwszego dnia i do 48,5% drugiego dnia. Wzrost zużycia własnego wpłynął na wymianę energii z siecią dystrybucyjną nN. Jak wspomniano wcześniej, po zoptymalizowaniu profilu operacyjnego magazynu energii RESS, w pierwszym analizowanym dniu dzienny eksport energii do sieci zmniejszył się z 7,6 kWh do 6,6 kWh, podczas gdy drugiego dnia zmniejszył się z 11,8 kWh do 7,9 kWh. Zastosowanie optymalizacji PSO celem jednoczesnego wysterowania RESS i określenia czasu załączania sterowanych odbiorników SL dodatkowo zmniejszyło ilość energii oddawanej do sieci elektroenergetycznej w obu dniach.

Przedstawione w tabelach 3.5 i 3.6 wyniki wskazują, że najlepsze efekty uzyskano dla łącznej optymalizacji pracy RESS oraz urządzeń domowych o sterowanym czasie załączania SL. W tych przypadkach zauważany był największy wzrost autokonsumpcji generowanej przez źródło PV energii i tym samym minimalizacja ilości energii oddawanej do sieci nN. Opracowany model systemu HEMS, maksymalizujący neutralność finansową prosumenta,

pozwała zatem zarządzać pracą urządzeń elektrycznych gospodarstwa domowego w taki sposób, aby zmniejszyć oddziaływanie mikroinstalacji PV na sieć dystrybucyjną, przy czym czynnikiem, który silnie wpływa na zachowanie algorytmu optymalizacyjnego, i tym samym na decyzje wypracowywane przez system HEMS, są ceny energii elektrycznej. Takiej możliwości nie posiadają systemy HEMS oparte na regułach.

Zaproponowany w [Z.5] system HEMS przynosi korzyści nie tylko prosumentowi, maksymalizując jego zużycie własne, ale także zmniejsza presję inwestycyjną na operatora systemu dystrybucyjnego, minimalizując negatywny wpływ prosumenckich mikroinstalacji fotowoltaicznych na sieć elektroenergetyczną. Dodatkowo przedstawiona architektura systemu HEMS jest ogólna i możliwa do zastosowania w każdym budynku mieszkalnym, dzięki czemu może być szeroko wdrażana w instalacjach prosumenckich. Opisany system HEMS został wdrożony w budynku, w którym wykonane zostały pomiary oraz w drugim budynku mieszkalnym wyposażonym również w instalację PV, magazyn baterijny RESS i odbiorniki znanych profilach poboru energii i sterowanym czasie załączania SL, w którym realizowane były (i są nadal) dalsze badania nad pracą systemu HEMS. Szczegółowy opis drugiego obiektu badań oraz zainstalowanego w nim systemu pomiarowo-sterującego został przedstawiony w kolejnej części autoreferatu, stanowiącego opis wykonanych prac wdrożeniowych.

4. OPIS OSIĄGNIĘĆ WDROŻENIOWYCH

4.1. Charakterystyka obiektu (budynku jednorodzinnego) i urządzeń elektrycznych w nim zainstalowanych

Obiektem, w którym przeprowadzono badania praktyczne rozwiązań opisanych w poprzednim rozdziale był dwukondygnacyjny budynek jednorodzinny z lat 70-tych XX wieku, o powierzchni użytkowej około 140 m². Na stałe zamieszkują w nim cztery dorosłe osoby, a roczne zużycie energii elektrycznej dla analizowanego obiektu wynosi około 4 MWh. Budynek ten został wybrany do badań, ponieważ zalicza się do najliczniejszej grupy budynków, którymi są domy jednorodzinne. W Polsce takich obiektów jest około 6,3 mln [22]. Z kolei średnia liczba osób wliczanych do gospodarstwa domowego wynosi 2,43, a zużycie energii elektrycznej na jednego mieszkańca wynosi średnio około 800 kWh/rok, wg danych opublikowanych przez GUS za rok 2024 [23].

Zasilanie analizowanego budynku jednorodzinnego zrealizowane jest napowietrznym przyłączem AsXSn 4×16 mm². Moc przyłączeniowa badanego obiektu wynosi 16 kW. W budynku instalacja elektryczna w części pomieszczeń wykonana jest w układzie TN-C, natomiast w pomieszczeniach, które były remontowane przewody elektryczne zostały wymienione i instalacja została zmodernizowana do układu TN-S. W rozdzielnicy głównej budynku zainstalowane są obecnie wyłączniki nadprądowe typu S o prądzie znamionowym 16 A oraz ogranicznik przepięć typu T1+T2.

W badanym budynku od roku 2019 roku pracuje prosumencka mikroinstalacja fotowoltaiczna o mocy znamionowej 6,1 kW. Instalacja składa się z dwudziestu krzemowych paneli monokrystalicznych o mocy 305 W każdy. Moduły zabudowane są na dachu budynku (rys. 4.1), posiadającym nachylenie około 15° i zorientowane są na południe. W ciągu całego roku panele PV nie są przysłaniane przez inne obiekty. Nad poprawnością pracy instalacji czuwa trójfazowy falownik marki Fornius Symo o mocy znamionowej 5 kW (sumaryczna moc zainstalowanych paneli została przewymiarowana w stosunku do mocy znamionowej falownika zgodnie z dopuszczalnymi wartościami podanymi przez producenta falownika dla zainstalowanego rodzaju paneli fotowoltaicznych). Omawiany budynek znajduje się około 700 m od stacji transformatorowej 20/0,4 kV i jest przedostatnim budynkiem w tym obwodzie zasilającym. W bezpośrednim sąsiedztwie znajdują się inne mikroinstalacje PV o łącznej mocy około 80 kW i pomimo wykonanej w ostatnim czasie głębokiej modernizacji sieci nN (obecnie linie napowietrzne sieci nN zasilające ten budynek są wykonane w technologii ASXSn i mają przekrój 70 mm²; zastąpiły one linie napowietrzne z przewodami gołymi AL o przekroju

50 mm²) okresowo występują przekroczenia dopuszczalnego poziomu napięcia, skutkujące wyłączeniem mikroinstalacji PV przez zabezpieczenia nadnapięciowe falownika.



Rys. 4.1. Prosumencka mikroinstalacja PV zintegrowana z analizowanym budynkiem mieszkalnym

W połowie 2023 roku zakupiony został magazyn energii elektrycznej RESS o pojemności znamionowej około 20 kWh. Magazyn ten składa się z modułu zarządzającego BMS (ang. Battery Management System), ośmiu ogniw o pojemności znamionowej 2,45 kWh każde, wykonanych w technologii LiFePO₄, oraz ładowarki (falownika) o mocy znamionowej 5 kW. Magazyn został zainstalowany i zintegrowany z instalacją elektryczną w omawianym budynku mieszkalnym wyposażonym w źródło PV. Na rysunku 4.2 przedstawiono zainstalowany magazyn energii wraz z ładowarką. Jak wcześniej wspomniano, opisany budynek został wykorzystywany do szczegółowego testowania opracowanej metody optymalnego sterowania pracą magazynu energii oraz odbiorników o sterowanym czasie załączania. Zainstalowane elementy stanowią razem instalację badawczą pracującą w rzeczywistych warunkach eksploatacyjnych.



Rys. 4.2. Magazyn energii RESS wraz z ładowarką, zainstalowany w analizowanym budynku mieszkalnym

Jak zaznaczono wcześniej, roczne zużycie energii elektrycznej w rozpatrywanym obiekcie wynosi około 4 MWh. Na taki poziom zużycia energii mają wpływ odbiorniki jakie są zainstalowane w tym budynku, a są to m.in. urządzenia RTV i AGD, oświetlenie, komputery, elektryczny zasobnik CWU, w którym w okresie letnim przygotowywana jest ciepła woda użytkowa. Urządzenia te można podzielić na dwie główne grupy. Pierwszą z nich są odbiorniki stanowiące zapotrzebowanie podstawowe budynku, które są załączane automatycznie przez własne układy sterowania i mogą pobierać energię w dowolnym czasie lub są włączane przez domowników w różnych porach dnia, wtedy gdy jest konieczność użytkowania wybranego urządzenia. Do tej grupy zaliczone zostały m.in.: lodówka, zamrażarka, sprzęt AGD, oświetlenie, komputery i telewizory. Odbiorniki te nie podlegają sterowaniu przez system HEMS, a prognoza zużycia energii przez te urządzenia stanowi prognozę bazowego profilu obciążenia obiektu. Drugą grupę odbiorników stanowią urządzenia, których czasem załączania można sterować (odbiorniki SL), co oznacza że wybrany odbiornik może zostać załączony


automatycznie przez system HEMS o dowolnej porze w ciągu doby lub w wybranym, zdefiniowanym przez użytkownika, okresie doby. Do tej grupy odbiorników zaliczono m.in.: pralki, zmywarkę i bojler elektryczny (zasobnik C.W.U). Innym przykładem odbiorników stosowanych w budownictwie jednorodzinny, które mogą być zaliczone do tej grupy urządzeń są m.in. pompa ciepła, klimatyzator oraz ładowarka samochodu lub roweru elektrycznego. Aktualnie urządzenia te nie są zainstalowane w badanym obiekcie.

4.2. Rozbudowa układu pomiarowego zainstalowanego w rozpatrywanym budynku mieszkalnym

4.2.1. Układ do pomiaru parametrów charakteryzujących pracę instalacji zasilającej w budynku

Przed modernizacją instalacji elektrycznej, w budynku scharakteryzowanym w poprzednim punkcie, obwody odbiorcze były zabezpieczone bezpiecznikami typu DII. Obok bezpieczników zlokalizowany był indukcyjny licznik energii elektrycznej. Przed montażem instalacji fotowoltaicznej została wykonana modernizacja tablicy licznikowej. Podczas wykonywania prac, zgodnie z warunkami technicznymi otrzymanymi od operatora systemu dystrybucyjnego, licznik energii elektrycznej został przeniesiony na zewnętrzną ścianę budynku. Nastąpiła także wymiana wewnętrznej linii zasilającej (WLZ), a istniejące bezpieczniki zostały wymienione na zabezpieczenia nadprądowe typu S. Po wykonaniu tych prac modernizacyjnych instalacji elektrycznej, w kolejnym etapie, na dachu budynku zainstalowano mikroinstalację fotowoltaiczną. Po zgłoszeniu gotowości przyłączenia źródła PV do sieci elektroenergetycznej pracownicy lokalnego OSD zainstalowali dwukierunkowy licznik energii elektrycznej Iskra MT174. Urządzenie to wykonane jest w 1 klasie dokładności dla pomiaru energii czynnej, oraz 2 klasie dla pomiaru energii biernej. Zainstalowany licznik wyposażony jest jedynie w wyjście impulsowe, co uniemożliwia (lub co najmniej znacząco utrudnia) wykorzystanie go w opracowanym systemie pomiarowym budynku, zatem aby można było odczytać różne parametry elektryczne na przyłączy budynku, konieczne było zainstalowane w tym miejscu dodatkowego licznika energii elektrycznej z wbudowanym modulem komunikacyjnym.

W celu kompleksowej rejestracji aktualnych parametrów charakteryzujących pracę, rozbudowanej o źródło PV i magazyn energii RESS, instalacji zasilającej w badanym budynku zostały wykonane zmiany w rozdzielnicy głównej, które obejmowały instalację czterech dodatkowych liczników energii (mierników parametrów sieci) oraz wymaganych do zasilania niektórych z nich przekładników prądowych. Tablicę licznikową po rozbudowie przedstawiono na rysunku 4.3.



Rys. 4.3. Układ pomiarowy w budynku mieszkalnym wyposażonym w instalację PV i magazyn energii po rozbudowie o dodatkowe liczniki energii

Widoczny na zdjęciu (rys. 4.3) licznik oznaczony numerem 1 jest zainstalowany za rozłącznikiem głównym FR 100 A. Jest to licznik marki Chint DTSU666, realizujący pomiar bezpośredni (nie wymaga instalacji przekładników). Urządzenie to charakteryzuje się dużą dokładnością, a procentowy zakres błędu dla pomiaru energii czynnej nie przekracza $\pm 1\%$. Licznik ten skomunikowany jest przewodowo z modulem zarządzającym baterią akumulatorów (z ładowarką magazynu energii). Urządzenia komunikują się między sobą poprzez protokół komunikacyjny Modbus RTU. Protokół ten realizuje szeregową wymianę informacji z innymi urządzeniami opartą na interfejsie RS-485. W tej topologii ładowarka magazynu energii pełni rolę elementu typu „master”, który odpytuje urządzenie typu „slave” (w tym przypadku licznik Chint DTSU666), a ten w odpowiedzi na zapytanie przesyła żądane dane do odpowiednich jej rejestrów. Najważniejszą informacją przekazywaną z licznika do ładowarki magazynu jest aktualna wartość wymiany energii z siecią elektroenergetyczną, gdyż na tej podstawie fabrycznie zaimplementowany, bazujący na regułach logicznych, algorytm sterowania magazynem określa pożądany punkt pracy RESS, pozwalający na jej minimalizację.

Kolejne liczniki energii elektrycznej widoczne na zdjęciu (rys. 4.3), oznaczone numerami 2, 3 i 4, są to liczniki marki F&F, model LE-03 MQ CT, realizujące półpośredni pomiar energii elektrycznej (i innych parametrów). Wymagają one podłączenia do instalacji za pomocą przekładników prądowych o znamionowym prądzie wtórnym równym 1 lub 5 A (odpowiednia wartość przekładni ustawiana jest w liczniku; w omawianej instalacji liczniki podłączono za pomocą przekładników prądowych o przekładni 40/5 A i klasie dokładności równej 1). Liczniki te posiadają certyfikat MID (Measuring Instruments Directive), co pozwala na legalne wykorzystanie tych urządzeń do rozliczeń handlowych w Unii Europejskiej. Procentowy zakres błędu tych liczników dla pomiaru energii czynnej nie przekracza $\pm 1\%$.


Licznik nr 2 służy do odczytu parametrów elektrycznych na zaciskach zasilających budynek (na przyłączy do sieci elektroenergetycznej nN). Należy zaznaczyć, że omówiony wcześniej licznik nr 1 oraz licznik nr 2 wykonują pomiary w tym samym miejscu (mierzą te same wartości). Montaż kolejnego licznika w rozdzielnicy (licznika nr 2) był jednak konieczny i wynikał z wcześniejszych (nieudanych) prób odczytu danych z zainstalowanego wcześniej licznika nr 1 przez kolejne urządzenie typu „master”, jakim jest serwer systemu pomiarowo-sterującego (odczyt licznika nr 1 przez dwa urządzenia typu „master” powodował przerwanie transmisji lub błędy w odczytywanych wartościach rejestrów).

Kolejny licznik (licznik nr 3) odczytuje parametry z instalacji fotowoltaicznej po stronie napięcia przemiennego. Pomiar parametrów odbywa się na odcinku instalacji pomiędzy falownikiem PV, a zabezpieczeniem zabudowanym w rozdzielnicy głównej budynku. Licznik nr 4 odczytuje natomiast parametry z magazynu energii, i podobnie jak dla licznika nr 3, pomiar odbywa się na odcinku pomiędzy ładowarką magazynu a zabezpieczeniem nadprądowym tego obwodu.

W celu odczytu różnorodnych parametrów kompleksowo charakteryzujących pracę omawianej instalacji zasilającej budynek mieszkalny, wyjścia komunikacyjne liczników nr 2, 3 i 4 zostały połączone szeregowo ze sobą, a do licznika nr 4 został podłączony konwerter RS-485/USB. Dzięki temu możliwy jest odczyt mierzonych wielkości przez mikrokomputer Raspberry Pi (pełniący rolę serwera systemu pomiarowo-sterującego) z zainstalowaną platformą Home Assistant. Opis sposobu odczytu danych przedstawiono w dalszej części opracowania.

4.2.2. Układ do pomiaru parametrów charakteryzujących pracę poszczególnych urządzeń elektrycznych

W celu wykorzystania różnych urządzeń elektrycznych w procesie kształtowania całkowitego zapotrzebowania budynku (jako odbiorniki SL o sterowanym czasie załączania) konieczna jest znajomość czasowego profilu poboru energii przez te odbiorniki. W tym celu przeprowadzone zostały odpowiednie pomiary, obrazujące m.in. zmienność poboru mocy w czasie pracy tych urządzeń. Aby zrealizować tego typu pomiary zbudowano przenośne stanowisko pomiarowe składające się z licznika energii elektrycznej, rejestratora (do tego wykorzystano mikrokomputer Raspberry Pi), wtyczki oraz gniazda elektrycznego. Stanowisko to pełniło rolę „przedłużacza elektrycznego” z rejestracją danych. Jego widok przedstawiono na poniższym zdjęciu (rys. 4.4). Do pomiaru profili pracy urządzeń wykorzystano licznik energii elektrycznej Orno OR-WE-504. Jest to jednofazowe urządzenie przeznaczone do monitorowania zużycia energii czynnej w instalacjach domowych i przemysłowych. Licznik ten realizuje bezpośredni pomiar energii czynnej w 1 klasie dokładności, lecz nie posiada certyfikatu MID. Jest on wyposażony w interfejs RS-485 z obsługą protokołu Modbus RTU. Protokół ten umożliwia zdalny odczyt danych, co czyni go odpowiednim do zastosowań w systemach automatyki budynkowej i monitoringu energii. Z urządzenia można odczytać dane dotyczące napięcia, prądu, częstotliwości, mocy czynnej, biernej i pozornej, współczynnika mocy, energii czynnej oraz biernej.



Rys. 4.4. Przenośne stanowisko pomiarowe do rejestracji profili pracy domowych urządzeń elektrycznych

Budowę przenośnego stanowiska do pomiaru profili pracy urządzeń gospodarstwa domowego rozpoczęto od wykonania fizycznego połączenia pomiędzy poszczególnymi elementami składowymi. Następnie opracowano algorytm, który umożliwił odczyt parametrów rejestrowanych przez licznik energii elektrycznej. W tym celu, na mikrokomputerze Raspberry Pi (RPi), został zainstalowany system operacyjny Raspberry Pi OS, w którym pracuje program IDLE, umożliwiający tworzenie algorytmów w języku programowania Python. W tym środowisku został stworzony i przetestowany kod realizujący odczyt danych z licznika energii elektrycznej, a następnie ich zapis do pliku csv z rozdzielczością pięciosekundową (rozdzielczość może być dowolnie zmieniana w kodzie programu). Kod ten przedstawiono na rysunku 4.5.

```
#!/usr/bin/python
from pymodbus.client import ModbusSerialClient as ModbusClient
import time
import csv
import os

# Funkcja do generowania unikalnej nazwy pliku
def get_unique_filename(folder, base_filename):
    # Sprawdzamy, czy plik istnieje
    i = 0
    while True:
        # Generujemy nazwę pliku
        if i == 0:
            filename = os.path.join(folder, base_filename + ".csv")
        else:
            filename = os.path.join(folder, base_filename + f"_{chr(97 + i)}.csv") # 97 to kod ASCII dla 'a'

        # Sprawdzamy, czy plik już istnieje
        if not os.path.exists(filename):
            return filename
        i += 1

# Ścieżka zapisu pliku CSV - dostosuj do Windows
folder = "/home/tom/Desktop/ORNO/ORNO"
os.makedirs(folder, exist_ok=True) # utworzy folder, jeśli nie istnieje

# Tworzymy nazwę pliku na podstawie daty
data = time.strftime("%d-%m-%Y")
base_filename = f"ORNO_{data}"

# Generujemy unikalną nazwę pliku
nazwaPliku = get_unique_filename(folder, base_filename)

print(f"Zapis danych do pliku: {nazwaPliku}")

start_time = time.time() # Zapisujemy czas początkowy

while True:
    try:
        # Inicjalizacja klienta Modbus RTU
        client = ModbusClient(
            port='/dev/ttyUSB0', # Upewnij się, że to prawidłowy port
            baudrate=9600,
            stopbits=1,
            parity='N',
            bytesize=8,
            timeout=1
        )
        client.connect()

        # Odczyt 15 rejestrów z adresu 0, slave ID = 1
        rr = client.read_holding_registers(address=0, count=15, slave=1)

        if rr.isError():
            print("Błąd Modbus:", rr)
            client.close()
            time.sleep(2)
            continue
```



```
# Parsowanie danych
Napiecie = float(value[0]) / 10
Prad = float(value[1]) / 10
Czestotliwosc = float(value[2]) / 10
Moc_czynna = float(value[3])
Moc_bierna = float(value[4])
Moc_pozorna = float(value[5])
Cos_fi = float(value[6]) / 1000
Energia_czynna = float(value[8]) / 1000
Energia_bierna = float(value[10])

client.close()

# Format liczbowy: zamiana . na ,
def zamien(liczba):
    return str(liczba).replace('.', ',')

U = zamien(Napiecie)
I = zamien(Prad)
Hz = zamien(Czestotliwosc)
P = zamien(Moc_czynna)
Q = zamien(Moc_bierna)
S = zamien(Moc_pozorna)
PF = zamien(Cos_fi)
kWh = zamien(Energia_czynna)
varh = zamien(Energia_bierna)

# Wyświetlanie
print(f"U={U} V, I={I} A, f={Hz} Hz, P={P} W, Q={Q} var, S={S} VA, PF={PF}, kWh={kWh}, varh={varh}")

# Zapis do pliku CSV co 5 sekund
elapsed_time = time.time() - start_time
if elapsed_time >= 5:
    start_time = time.time() # Resetujemy czas początkowy

    # Zapisujemy dane do pliku
    godzina = time.strftime("%H:%M:%S")
    dane = [data, godzina, U, I, Hz, P, Q, S, PF, kWh, varh]


    with open(nazwaPliku, "a", newline="") as f:
        writer = csv.writer(f, delimiter=',', dialect=csv.excel)
        writer.writerow(dane)

    print(f"Zapisano dane o {godzina}") # Debugging info

except Exception as e:
    print("Błąd ogólny:", e)
    time.sleep(5) # Czas oczekiwania po błędzie
```

Rys. 4.5. Kod algorytmu odczytu i zapisu danych pomiarowych rejestrowanych przez licznik energii elektrycznej


Ponieważ przenośny rejestrator profili został zbudowany w formie „przedłużacza elektrycznego”, to rejestracja profili pracy urządzeń odbywała się poprzez podłączenie wtyczki urządzenia, którego profil ma zostać zarejestrowany do gniazda elektrycznego rejestratora, a następnie zasilenie rejestratora z sieci. Dodatkowo należy podłączyć zasilanie do mikrokomputera RPi, co powoduje samoczynne uruchomienie opracowanego algorytmu odczytu i zapisu danych pomiarowych. Dane pomiarowe z licznika energii elektrycznej są odczytywane w rozdzielczości pięciosekundowej z wykorzystaniem protokołu Modbus RTU. Na rysunku 4.6 przedstawione zostały zarejestrowane profile pracy pralki, zmywarki oraz bojlera elektrycznego. Przedstawione wykresy są jednymi z kilku zarejestrowanych profili pracy tych urządzeń (zarejestrowano profile wynikające z różnych programów ich pracy).




Rys. 4.6. Zarejestrowane profile pracy: pralki (a), zmywarki (b), bojlera elektrycznego (c)

Wyniki pomiarów rejestrowane przez jednofazowy licznik energii elektrycznej Orno zostały poddane analizie porównawczej z wynikami uzyskanymi przez renomowane urządzenie rejestrujące parametry pracy sieci elektroenergetycznej. Urządzeniem tym był miernik Fluke 1773, który umożliwia pomiar różnych parametrów elektrycznych z dokładnością wynoszącą 0,5%. Wykonano pomiary porównawcze dla dwóch odbiorników. W pierwszym z przeprowadzonych badań wykorzystano odbiornik o charakterze rezystancyjnym, jakim był grzejnik elektryczny o dwóch poziomach mocy grzewczej. Zarejestrowane profile poboru mocy

przez to urządzenie przedstawiono na rysunku 4.7. Z kolei na rysunku 4.8 przedstawiono profile uzyskane podczas drugiego badania, w którym rejestrowano pracę odbiornika rezystancyjno-indukcyjnego (trójbiegowy wentylator pokojowy). W tabeli 4.1 podano minimalne, średnie i maksymalne wartości błędów względnych pomiaru mocy czynnej (wyniki uzyskane przez miernik Fluke zostały potraktowane jako wartość dokładna). Uzyskane wyniki wskazują, że zastosowany jednofazowy licznik energii elektrycznej Orno charakteryzuje się stosunkowo wysoką dokładnością pomiarową i nadaje się do zastosowania w celu rejestracji profili pracy urządzeń domowych. Dla odbiornika o większym poborze mocy czynnej (grzejnik) średni błąd względny pomiaru miał niższą wartość. Najwyższe wartości błędów wystąpiły w czasie załączania badanego urządzenia.



Rys. 4.7. Profile poboru mocy czynnej przez grzejnik elektryczny zarejestrowane za pomocą licznika Orno oraz miernika Fluke



Rys. 4.8. Profile poboru mocy czynnej przez trójbiegowy wentylator zarejestrowane za pomocą licznika Orno oraz miernika Fluke

Tabela. 4.1.

Względne błędy pomiaru mocy czynnej za pomocą licznika Orno

Urządzenie	Względny błąd pomiaru, w %		
	minimalny	średni	maksymalny
Grzejnik	0,00	2,05	11,26
Wentylator	0,00	5,65	83,33

4.3. Home Assistant jako otwarta platforma pomiarowo-sterująca

Poszukując platformy, która posłuży do zbudowania systemu pomiarowo-sterującego starano się znaleźć rozwiązanie, które umożliwi swobodną rejestrację danych z liczników pomiarowych oraz ich wizualizację, a jednocześnie będzie odpowiednio elastyczne i podatne na modyfikacje, aby w kolejnym kroku można je było wykorzystać do zbudowania systemu sterowania różnymi urządzeniami zainstalowanymi w budynku. Wybór padł na system Home Assistant (HA) [32], który jest otwartoźródłową platformą służącą do automatyzacji inteligentnego domu, umożliwiającą monitorowanie i sterowanie urządzeniami pracującymi według różnych standardów. Obecnie system ten oferuje ponad 1500 tzw. integracji (aplikacji), które oferują wsparcie dla nowych urządzeń, protokołów, umożliwiają modyfikacje lub rozszerzenie interfejsu użytkownika, a także połączenie HA z różnymi usługami zewnętrznymi. Platforma Home Assistant działa lokalnie, bez potrzeby korzystania z chmury, co zapewnia większą prywatność i bezpieczeństwo oraz szybkość działania. System ten może zostać zainstalowany na mikrokomputerze, laptopie lub komputerze stacjonarnym. W badanym obiekcie wybrano mikrokomputer RPi, który charakteryzuje się niewielkimi rozmiarami, posiada parametry obliczeniowe pozwalające na bezproblemowe działanie systemu HA oraz jest przystępny cenowo.

4.3.1. Home Assistant – funkcje pomiarowe

W rozpatrywanym budynku platforma HA została wdrożona w pierwszej kolejności w celu odczytu i rejestracji danych pomiarowych z zainstalowanych liczników energii elektrycznej (opisano je w punkcie 4.2.1). Jak wspomniano wcześniej, odczyt ten został zrealizowany za pomocą konwertera RS-485/USB, który jest podłączony do portu USB mikrokomputera RPi, na którym zainstalowano HA. Liczniki zostały połączone ze sobą szeregowo i każdemu z nich nadano indywidualny i niepowtarzalny identyfikator. Taki typ połączenia jest wymuszony przez protokół komunikacyjny Modbus RTU, w którym poszczególne urządzenia przesyłają dane szeregowo w ustalonym formacie binarnym. Od strony programowej w systemie operacyjnym HA stworzono algorytm, który odczytuje dane z liczników. Fragment kodu


odczytujących wartości napięcia z liczników pokazano na rys. 4.9. Z kolei szczegółowe pomiary odczytywane z liczników wskazanych powyżej przedstawiono na rysunku 4.10. Oprócz prezentacji w interfejsie użytkownika HA, dane dotyczące poziomów napięć, prądów, mocy czynnych i biernych, współczynnika mocy i innych parametrów są zapisywane również do pliku csv z rozdzielczością minutową. Zapisane dane są wykorzystywane do opracowania prognozy bazowego zapotrzebowania budynku, ale również zostały wykorzystane do celów testowania opracowanej metody sterowania pracą magazynu i odbiornikami o sterowanym czasie załączania. Mierzone wielkości pozwalają ponadto na przejrzystą wizualizację przepływów energii w analizowanym budynku, co przedstawia rysunek 4.11.

```
1 * # Modbus configuration
2 * #USB1 -- licznik parametrów sieci zasilającej
3   --- name: hub1
4   --- type: serial
5   --- method: rtu
6 * --- port: /dev/ttyUSB0
7   --- port: /dev/serial/by-id/usb-FTDI_FT232R_USB_UART_AQ827BVD-if00-port0
8 * # --- /dev/serial/by-path/platform-fd500000.pcie-pci-0000:01:00.0-usb-0:1.2:1.0-port0
9   --- baudrate: 9600
10  --- stopbits: 1
11  --- bytesize: 8
12  --- parity: N
13  --- timeout: 1
14  --- sensors:
15 * #Napiecie L1-N
16 * --- name: U L1
17 * --- unit_of_measurement: V
18 * --- device_class: power
19 * --- slave: 1
20 * --- address: 0
21 * --- input_type: input
22 * # --- count: 2
23 * --- data_type: float32
24 * --- precision: 2
25 * --- scale: 1
26 * #Napiecie L2-N
27 * --- name: U L2
28 * --- device_class: power
29 * --- unit_of_measurement: V
30 * --- slave: 1
31 * --- address: 2
32 * --- input_type: input
33 * # --- count: 2
34 * --- data_type: float32
35 * --- precision: 2
36 * --- scale: 1
37 * #Napiecie L3-N
38 * --- name: U L3
39 * --- unit_of_measurement: V
40 * --- device_class: power
41 * --- slave: 1
42 * --- address: 4
43 * --- input_type: input
44 * # --- count: 2
45 * --- data_type: float32
46 * --- precision: 2
47 * --- scale: 1
48 * #Prad I L1
49 * --- name: I L1
50 * --- unit_of_measurement: A
51 * --- slave: 1
52 * --- address: 6
53 * --- input_type: input
54 * # --- count: 2
55 * --- data_type: float32
56 * --- precision: 2
57 * --- scale: 1
58 * #Prad L2
59 * --- name: I L2
60 * --- unit_of_measurement: A
61 * --- slave: 1
62 * --- address: 8
63 * --- input_type: input
64 * # --- count: 2
65 * --- data_type: float32
66 * --- precision: 2
67 * --- scale: 1
```

Rys. 4.9. Fragment kodu umożliwiającego odczyt danych z zainstalowanych liczników


Licznik nr 2 (Przylącze budynku)		Licznik nr 3 (Instalacja PV)		Licznik nr 4 (Magazyn energii)	
⚡ U L1	238,52 V	⚡ Licznik_PV U L1	238,56 V	⚡ Licznik_MAG U L1	238,31 V
⚡ U L2	233,41 V	⚡ Licznik_PV U L2	232,82 V	⚡ Licznik_MAG U L2	232,78 V
⚡ U L3	238,81 V	⚡ Licznik_PV U L3	238,70 V	⚡ Licznik_MAG U L3	238,56 V
🌀 I L1	0,73 A	🌀 Licznik_PV I L1	0,00 A	🌀 Licznik_MAG I L1	0,65 A
🌀 I L2	0,70 A	🌀 Licznik_PV I L2	0,00 A	🌀 Licznik_MAG I L2	0,65 A
🌀 I L3	0,75 A	🌀 Licznik_PV I L3	0,00 A	🌀 Licznik_MAG I L3	0,85 A
🌀 P L1	80,36 W	🌀 Licznik_PV P L1	0,00 W	🌀 Licznik_MAG P L1	0,0 W
🌀 P L2	0,00 W	🌀 Licznik_PV P L2	0,00 W	🌀 Licznik_MAG P L2	0,0 W
🌀 P L3	-104,90 W	🌀 Licznik_PV P L3	0,00 W	🌀 Licznik_MAG P L3	0,0 W
🌀 Q L1	-153 Var	🌀 Licznik_PV Q L1	0 Var	🌀 Licznik_MAG Q L1	0 Var
🌀 Q L2	89 Var	🌀 Licznik_PV Q L2	0 Var	🌀 Licznik_MAG Q L2	0 Var
🌀 Q L3	-89 Var	🌀 Licznik_PV Q L3	0 Var	🌀 Licznik_MAG Q L3	0 Var
🌀 L1-L2	408,76 V	🌀 Licznik_PV L1-L2	408,18 V	🌀 Licznik_MAG L1-L2	407,88 V
🌀 L2-L3	408,76 V	🌀 Licznik_PV L2-L3	408,43 V	🌀 Licznik_MAG L2-L3	408,21 V
🌀 L3-L1	413,73 V	🌀 Licznik_PV L3-L1	413,24 V	🌀 Licznik_MAG L3-L1	412,87 V
🌀 f	49,99 Hz	🌀 Licznik_PV f	50,00 Hz	🌀 Licznik_MAG f	50,00 Hz
🌀 I0	0,00 A	🌀 Licznik_PV I0	0,00 A	🌀 Licznik_MAG I0	0,00 A
🌀 cos	-0,28	🌀 Licznik_PV cos	1,00	🌀 Licznik_MAG cos	1,00
🌀 cos L1	0,45	🌀 Licznik_PV cos L1	1,00	🌀 Licznik_MAG cos L1	1,00
🌀 cos L2	-0,13	🌀 Licznik_PV cos L2	1,00	🌀 Licznik_MAG cos L2	1,00
🌀 cos L3	-0,77	🌀 Licznik_PV cos L3	1,00	🌀 Licznik_MAG cos L3	1,00
🌀 Psum	0 W	🌀 Licznik_PV Psum	0 W	🌀 Licznik_MAG Psum	0,0 W
🌀 Qsum	-154 Var	🌀 Licznik_PV Qsum	0 Var	🌀 Licznik_MAG Qsum	0,00 Var
🌀 P Import	9315,89 kWh	🌀 Licznik_PV P Import	11,88 kWh	🌀 Licznik_MAG P Import	1224,32 kWh
🌀 P Eksport	16 150,61 kWh	🌀 Licznik_PV P Eksport	13 706,04 kWh	🌀 Licznik_MAG P Eksport	786,47 kWh
🌀 Q Import	2746,58 kVar	🌀 Licznik_PV Q Import	30,44 kVar	🌀 Licznik_MAG Q Import	429,24 kVar
🌀 Q Eksport	6129,16 kVar	🌀 Licznik_PV Q Eksport	871,52 kVar	🌀 Licznik_MAG Q Eksport	0,19 kVar

Rys. 4.10. Parametry elektryczne mierzone w instalacji zasilającej rozpatrywanego budynku mieszkalnego



Rys. 4.11. Godzinowe przepływy energii w analizowanym budynku mieszkalnym (kolor pomarańczowy – generacja PV, kolor różowy – ładowanie magazynu, kolor zielony – rozładowanie magazynu, kolor niebieski – import z sieci, kolor fioletowy – eksport do sieci) w dniu 19 maja 2025 r.

Wykorzystując możliwości systemu HA, na głównym panelu platformy, stworzono również grafikę informującą o aktualnych wartościach podstawowych parametrów charakteryzujących bieżącą pracę instalacji zasilającej budynku. Na utworzonej wizualizacji (rys. 4.12) wyświetlane są: aktualne zapotrzebowanie budynku, moc wymieniana z siecią elektroenergetyczną, generacja źródła PV, moc magazynu (ładowanie lub rozładowanie) oraz stopień jego naładowania. Wyświetlany jest również dobowy współczynnik autokonsumpcji oraz pokazywana jest numeryczna prognoza pogody, która jest podstawą do opracowania prognozy generacji źródła PV.



Rys. 4.12. Widok panelu głównego platformy Home Assistant

Odczytywane dane pomiarowe z liczników energii elektrycznej są rejestrowane w pamięci RPi. Dzięki temu istnieje możliwość przeprowadzenia szczegółowej analizy warunków pracy instalacji zasilającej w budynku w dowolnym dniu w przeszłości. W tym celu w HA zostały zainstalowane dodatki InfluxDB oraz Grafana. InfluxDB to wyspecjalizowana baza danych typu TSDB (Time Series Database), czyli baza danych szeregów czasowych. Została ona zaprojektowana do przechowywania, analizowania i przetwarzania dużej ilości danych zmieniających się w czasie, co sprawia, że jest ona idealna do współpracy z Home Assistant.

Z kolei Grafana jest narzędziem służącym do wizualizacji danych zbieranych przez Home Assistant w postaci interaktywnych wykresów i pulpitów (tzw. dashboardów). Grafana pozwala tworzyć atrakcyjne graficznie, zaawansowane analizy danych z czujników i urządzeń inteligentnego domu.

Korzystając z funkcjonalności obu dodatków, w środowisku graficznym Grafana zostały utworzone wykresy przedstawiające m.in. zarejestrowane poziomy napięcia (odczytane przez licznik nr 2) oraz generację źródła PV (odczytaną przez licznik nr 3). Na wykresie przedstawiającym zmierzone wartości napięcia zostały dodatkowo umieszczone poziome przerywane linie, które oznaczają dopuszczalne odchylenia napięcia zasilającego, wynoszące $\pm 10\% U_n$ (tzn. minimalne dopuszczalne napięcie jest równe 207 V, a maksymalne 253 V). Dla zilustrowania funkcjonalności omawianych dodatków, na rysunku 4.13.a uwidoczniono wartości napięć w dniu, w którym zostały przekroczone dopuszczalne poziomy napięcia w sieci elektroenergetycznej, a na rysunku 4.13.b konsekwencje tej sytuacji napięciowej dla pracy źródła PV (zbyt wysokie poziomy napięcia spowodowały wielokrotne wyłączenia falownika instalacji PV, co skutkowało przerwami w generacji energii). Z kolei na rysunku 4.14.a zilustrowano sytuację napięciową w dniu, w którym napięcia fazowe mieściły się w dopuszczalnych granicach. W tym dniu mikroinstalacja PV pracowała bez zakłóceń (rys. 4.14.b). Posiadanie tego typu informacji pozwala prosumentowi na lepsze zrozumienie warunków pracy swojego źródła PV.




Rys. 4.13. Przebiegi napięć fazowych (a) oraz generacja źródła PV (b) w dniu 21.05.2025 r. – przerwy w pracy mikroinstalacji PV w wyniku przekroczenia dopuszczalnego poziomu napięcia



Rys. 4.14. Przebiegi napięć fazowych (a) oraz generacja źródła PV (b) w dniu 19.05.2025 r. – normalna praca mikroinstalacji PV

Platforma Home Assistant umożliwia również wyznaczenie obciążenia podstawowego (bazowego), czyli obciążenia budynku, wynikającego z pracy odbiorników, które są załączane automatycznie przez własne układy sterowania lub są włączane przez domowników wtedy, gdy zaistnieje konieczność użytkowania wybranego urządzenia (lodówka, zamrażarka, sprzęt AGD, oświetlenie, komputery i telewizory). Obciążenie bazowe (podstawowe) budynku jest obliczane w karcie „Energia”. W tym celu HA wykorzystuje dane pomiarowe pochodzące

z zainstalowanych w budynku liczników energii oraz gniazdek sterowanych (opisanych w dalszej części) zasilających odbiorniki SL, przy czym wyniki są prezentowane w rozdzielczości godzinowej. Przykładowe wyniki przedstawiono na rysunku 4.15 (profil obciążenia bazowego budynku jest pokazany szarym kolorem). Zarejestrowane profile obciążenia bazowego budynku stanowią zbiór historycznych danych pomiarowych, wykorzystywanych do prognozowania obciążenia bazowego, zgodnie z metodą opisaną w punkcie 3.1.



Rys. 4.15. Wykresy godzinowe (a) przepływów energii w budynku, (b) szczegółowego zużycia z zaznaczonym poborem przez urządzenia o sterowanym czasie załączania (odbiorniki SL), (c) zapotrzebowania bazowego (podstawowego) w dniu 05.06.2025 r.

4.3.2. Home Assistant – funkcje sterujące


Kolejnym etapem wdrożenia było wykorzystanie platformy Home Assistant jako systemu do sterowania wybranymi odbiornikami o elastycznym czasie załączania i znanym profilu poboru energii (odbiorniki SL). Wykorzystano tutaj profile pracy różnych urządzeń gospodarstwa domowego, tj. pralek, zmywarki, bojlera elektrycznego, zarejestrowane metodą

opisaną w punkcie 4.2.2, dzięki czemu możliwe jest odpowiednie sterowanie czasem ich załączania w taki sposób, aby w maksymalnym stopniu wykorzystać generację PV.


Zainstalowane w analizowanym budynku mieszkalnym odbiorniki SL są urządzeniami starszego typu, które nie posiadają funkcji zdalnego załączania z wykorzystaniem np. aplikacji na telefon. Zatem, w celu umożliwienia ich zdalnego załączania w odpowiedniej chwili, konieczne było opracowanie innego rozwiązania. W ramach wykonanych prac, do sterowania tymi urządzeniami wykorzystano sterowane gniazda sieciowe typu WiFi Shelly Plus S (rys. 4.16). Gniazdko Shelly to seria inteligentnych urządzeń do automatyki domowej, które umożliwiają zdalne sterowanie podłączonymi do nich urządzeniami elektrycznymi (w tym przypadku odbiornikami SL, którymi w omawianym budynku są dwie pralki, zmywarka i bojler elektryczny). Podstawowo gniazdko te można załączać i wyłączać za pomocą aplikacji producenta zainstalowanej na telefonie lub fizycznym przyciskiem znajdującym się na obudowie. Po ich zintegrowaniu z platformą Home Assistant sterowanie gniazdkami jest możliwe także z tego poziomu (rys. 4.17). Oprócz funkcji zdalnego załączania, urządzenia te posiadają również możliwość rejestracji zużycia energii elektrycznej, poziomu napięcia, natężenia prądu oraz aktualnej mocy pobieranej przez podłączone urządzenie, co umożliwia bieżącą kontrolę jego pracy. Te dane pomiarowe są dodatkowo rejestrowane przez platformę HA, dzięki czemu użytkownik ma do dyspozycji historię pracy odbiorników SL. Przykład zarejestrowanego przez gniazdko Shelly profilu pracy przykładowego odbiornika SL (pralka) przedstawiono na rysunku 4.18.



Rys. 4.16. Gniazdko WiFi Shelly Plus S wykorzystane do zdalnego załączania odbiorników SL



Rys. 4.17. Panel służący do sterowania gniazdkami WiFi Shelly Plus S z poziomu interfejsu platformy HA



Rys. 4.18. Zarejestrowany przez gniazdko sterowane profil pracy przykładowego urządzenia SL (pralka)


W ramach dalszych prac wdrożeniowych, na platformie HA, został zaimplementowany układ sterowania gniazdkami WiFi Shelly Plus S, stosowany do automatycznego sterowania urządzeniami SL. W tym celu wykorzystano narzędzie Node-RED. Jest to narzędzie typu open-source stworzone przez IBM, które umożliwia tworzenie aplikacji poprzez graficzne łączenie bloków funkcyjnych (tzw. „node’ów”) w odpowiedni zestaw, nazywany diagramem przepływów (tzw. „flow”), realizujący wymagane przez użytkownika zadanie. System Node-RED posiada predefiniowane bloki funkcyjne, które realizują konkretne działania, np. odczyt, zapis i przetwarzanie danych, komunikację z urządzeniami zewnętrznymi z wykorzystaniem protokołów Modbus, MQTT lub innych, oraz umożliwiające wizualizację danych. Node-RED służy głównie do programowania w sposób wizualny, za pomocą przeciągania i łączenia poszczególnych elementów (bloków funkcyjnych) na diagramie przepływu, co czyni go

idealnym narzędziem dla osób niebędących programistami, jak również dla szybkiego prototypowania przez profesjonalistów.

W opracowanym algorytmie sterowania gniazdkami zasilającymi odbiorniki SL wykorzystano trzy typy bloków funkcyjnych realizujących następujące zadania:


1. blok „Harmonogram pracy”, który jest blokiem typu „Time”, realizującym wyzwalanie czasowe według przygotowanego planu pracy,
2. blok „Czas pracy urządzenia”, który jest blokiem typu „Delay”, przesyłającym informację do kolejnego bloku funkcyjnego po zadanej zwłoce czasowej,
3. bloki „Załącz” i „Wyłącz”, będące blokami typu „Action”, które realizują różne funkcje; w opisywanym zastosowaniu pierwszy blok załącza gniazdko po otrzymaniu informacji z bloku „Harmonogram pracy”, natomiast drugi blok wyłącza gniazdko, gdy taka informacja zostanie podana jako sygnał wejściowy do tego bloku.

Opracowany algorytm sterowania gniazdkami WiFi Shelly Plus S przedstawiono na rys. 4.19.a, natomiast na rys. 4.19.b i 4.19.c pokazano przykładowy test jego funkcjonalności (odpowiednio pokazano zadany harmonogram oraz zarejestrowaną pracę przykładowego urządzenia (w badaniach zastosowano żarówkę o mocy 40 W)). Jak widać opracowany algorytm umożliwia automatyczne załączenie i wyłączenie urządzenia, zgodnie z ustalonym harmonogramem jego pracy.



Rys. 4.19. Algorytm sterowania gniazdkami WiFi Shelly Plus S według zadanego harmonogramu pracy (a), przykładowy harmonogram pracy urządzenia sterowanego (b), zarejestrowana praca urządzenia (c)

W kolejnym etapie prac wdrożeniowych, na platformie Home Assistant został zaimplementowany układ do sterowania magazynem energii, który umożliwia zdalną zmianę punktu pracy ładowarki, wynikającą z zadanego, np. wyznaczonego przez zewnętrzny algorytm optymalizacyjny, harmonogramu jej pracy. W tym celu również wykorzystano narzędzie Node-RED. W pierwszym kroku został stworzony algorytm przedstawiony na rysunku 4.20. Algorytm ten odczytuje parametry udostępniane przez magazyn energii elektrycznej w odpowiednich rejestrach ładowarki. Są to informacje dotyczące (kolejno od góry): mocy wymiany z siecią w trzech fazach, mocy ładowarki w trzech fazach, napięcia, prądu, mocy i temperatury baterii akumulatorów oraz stanu jej naładowania. Algorytm rozpoczyna swoją pracę od wyzwolenia bloku „Time”. Blok ten realizuje funkcję wyzwalacza czasowego i ponawia swoje działanie z określonym, zadaniem przez użytkownika. interwałem czasowym. Kolejne bloki funkcyjne („Flex Getter”) zawierają adresy rejestrów ładowarki, z których mają być odczytane dane pomiarowe. Bloki te umożliwiają dynamiczne pobieranie danych z urządzenia wyposażonego w protokół komunikacyjny Modbus. Odczytane dane są następnie przekształcane przez bloki „Parser”, które dokonują ich konwersji do wymaganego przez użytkownika formatu liczbowego. W następnych blokach („Function”) wykonywane jest skalowanie odczytanych wartości, które są finalnie wyświetlane przez ostatnie bloki funkcyjne typu „Sensor”. Opisany algorytm działa na bieżąco w zbudowanym systemie pomiarowo-sterującym, realizując pomiary z jednoczesnym krokiem czasowym. Zmierzone wartości są rejestrowane w HA oraz wizualizowane na odpowiednich wykresach, dzięki czemu użytkownik posiada aktualną i historyczną informację o stanie pracy magazynu. Przykłady odczytanych przy użyciu algorytmu Node-RED wartości przedstawiono na rysunku 4.21.




Rys. 4.20. Algorytm Node-RED umożliwiające odczytywanie danych z rejestrów magazynu energii




Rys. 4.21. Wykresy przedstawiające odczytane przy użyciu algorytmu Node-RED przykładowe wartości rejestrów ładowarki magazynu: (a) stopień naładowania magazynu, (b) temperatura baterii akumulatorów, (c) moc magazynu energii

Oprócz rejestrów służących tylko do odczytu, ładowarka magazynu energii posiada również rejestry, do których można zapisywać dane, wywołując w ten sposób odpowiednią reakcję magazynu. Przykładami takich rejestrów są rejestry, w których można zadawać tryb pracy magazynu (sterowanie zdalne lub sterowanie lokalne przez fabrycznie zaimplementowany algorytm) oraz określać czas w jakim tryb zdalnego sterowania ma być aktywny (fabrycznie magazyn ma aktywowany tryb sterowania lokalnego, w którym punkt pracy magazynu jest zadawany przez algorytm oparty na regułach logicznych). Kolejnymi rejestrami posiadającymi funkcję zapisu są rejestry, w których można zadawać moc ładowania i moc rozładowania magazynu, w trybie sterowania zdalnego. Rejestry te zostały wykorzystane w zaimplementowanym w systemie pomiarowo-sterującym HA, w opracowanym w Node-RED algorytmie sterowania magazynem, który został pokazany na rysunku 4.22.



Rys. 4.22. Algorytm zdalnego sterowania ładowarką magazynu energii w Node-RED




Rys. 4.23. Wewnętrzny algorytm podprogramu „Odczyt planu pracy”

Algorytm zdalnego sterowania ładowarką magazynu składa się z następujących bloków funkcyjnych:

1. blok „Time” – opisany jako „Wyzwalacz”, który realizuje wyzwalanie czasowe algorytmu z interwałem jednominutowym,
2. blok „Subflow” – opisany jako „Odczyt planu pracy”; jest to podprogram, który odczytuje przygotowany w formacie csv plik zawierający program pracy magazynu, w którym zadana jest moc ładowania lub rozładowania dla każdej godziny doby (założono, że zadawany jest dobowy harmonogram pracy magazynu w rozdzielczości godzinowej, przy czym algorytm sterowania umożliwia określenie dowolnego horyzontu czasowego oraz dowolnej rozdzielczości tego harmonogramu); opracowany podprogram działa w ten sposób, że odczytane dane są najpierw konwertowane na format JSON, a następnie wyszukiwana jest zadana wartość mocy dla aktualnego czasu; podprogram „Odczyt planu pracy” został przedstawiony na rysunku 4.23,
3. blok „Switch” – opisany jako „Rozładowanie (+) czy ładowanie (-)?”, w którym algorytm sprawdza jaka wartość została odczytana z pliku zawierającego punkty pracy magazynu, a następnie przesyła informację do odpowiedniej gałęzi, w której realizowane jest zdalne zadawanie punktu pracy magazynu,
4. bloki „Change” – opisane jako „Konwersja”, w których zostały zaszyte funkcje matematyczne umożliwiające przekształcenie odczytanego punktu pracy z pliku csv do wartości przyjmowanych przez rejestry magazynu energii,
5. bloki „Function” – opisane jako „Moc rozładowania” oraz „Moc ładowania”, w których wewnątrz zapisane są odpowiednie rejestry magazynu energii, do których należy przesłać punkty pracy magazynu,
6. blok „Flex Write”, będący blokiem wykonawczym, który realizuje bezpośrednio funkcję zapisu danych do wskazanych rejestrów magazynu energii, zmieniając w ten sposób jego bieżący punkt pracy.

Celem weryfikacji poprawności działania opracowanego w środowisku Node-RED algorytmu zdalnego sterowania magazynem przeprowadzono szereg testów, polegających na zadawaniu różnych punktów pracy magazynu energii i obserwacji jego zachowania. Na początku testów należy aktywować sterowanie zdalne, które włącza się z poziomu systemu Home Assistant, za pomocą zmiany wartości odpowiedniego rejestru ładowarki magazynu z 0 na 1 (wartość rejestru równa 0 oznacza, że magazyn jest sterowany za pomocą fabrycznie zaimplementowanego algorytmu, który minimalizuje moc wymienianą między budynkiem

a siecią elektroenergetyczną). Po aktywowaniu sterowania zdalnego można następnie ustawić czas trwania tego sterowania oraz moc rozładowania lub ładowania magazynu. Na rysunku 4.24 przedstawiono przykładowy zadany profil pracy magazynu sterowanego zdalnie z poziomu platformy Home Assistant. Podczas tego eksperymentu, algorytm opracowany w narzędziu Node-RED odczytywał z przygotowanego w pliku csv planu pracy różne wartości mocy rozładowania i ładowania magazynu energii (magazyn był naładowany w około 88% w momencie rozpoczęcia testów). Na kolejnym rysunku (rys. 4.25) pokazano natomiast zarejestrowany, rzeczywisty profil magazynu sterowanego zgodnie z profilem zadany z rys. 4.24. Wartości dodatnie oznaczają, że magazyn rozładowywał się, natomiast ujemne wartości reprezentują ładowanie magazynu. Przeprowadzone testy sterowania magazynem pokazały możliwość dowolnej zmiany punktu pracy magazynu w pełnym zakresie mocy ładowarki, czyli od 5000 W do -5000 W (ograniczenie na dopuszczalny poziom SoC jest uwzględniane automatycznie przez układ kontroli magazynu). Punkty pracy można także zmieniać skokowo między maksymalną mocą ładowania i rozładowania, co dodatkowo udowadnia wysoką elastyczność pracy magazynu energii. Zrealizowane testy potwierdziły zatem możliwość pełnego kontrolowania punktu pracy magazynu za pomocą opracowanej metody sterowania tym urządzeniem, z wykorzystaniem platformy Home Assistant i oprogramowania Node-RED.



Rys. 4.24. Zadany profil pracy magazynu podczas zdalnego sterowania z poziomu Home Assistant




Rys. 4.25. Zarejestrowany profil pracy magazynu podczas zdalnego sterowania od 5000 W do -5000 W z krokiem 1000 W z poziomu Home Assistant

Powyżej wykazano, że przygotowane w środowisku Node-RED algorytmy umożliwiają zdalne załączanie wybranych odbiorników oraz zdalne sterowanie pracą magazynu energii według zadanych harmonogramów pracy tych urządzeń. W kolejnym punkcie autoreferatu przedstawione zostaną wyniki pomiarów ilustrujących działanie opracowanego systemu sterowania w rzeczywistym środowisku pracy.

5. OCENA EFEKTÓW IMPLEMENTACJI OPRACOWANEGO SYSTEMU HEMS W RZECZYWISTYM ŚRODOWISKU PRACY

Omówiony szczegółowo w poprzednim rozdziale system pomiarowo-sterujący zrealizowany na platformie Home Assistant został przedstawiony schematycznie na rysunku 5.1. Liniami przerywanymi zaznaczono drogi przepływu informacji między poszczególnymi elementami układu. Czerwone linie oznaczają drogi przepływu danych pomiarowych oraz prognoz, natomiast kolorem zielonym zobrazowano drogi przepływu sygnałów sterujących.



Rys. 5.1. Schemat opracowanego układu pomiarowo-sterującego zarządzającego pracą instalacji elektrycznej w budynku mieszkalnym wyposażonym w źródło PV, magazyn energii oraz sterowane odbiorniki o elastycznym czasie załączenia

Opracowany system pomiarowo-sterujący, działający z wykorzystaniem rozwiązań przedstawionych w poprzedniej części autoreferatu oraz w poszczególnych publikacjach tworzących rozprawę doktorską, zaimplementowano w rzeczywistym środowisku eksploatacyjnym jakim jest budynek jednorodzinny opisany w rozdziale 4.1. Celem wdrożenia

opracowanego systemu HEMS była ocena przydatności i efektywności tego rozwiązania w procesie kształtowania bilansu energetycznego budynku wyposażonego w mikroinstalację PV. Badanie podzielono na trzy etapy, z których każdy trwał tydzień. Obejmowały one:

1. sterowanie magazynem za pomocą fabrycznie zaimplementowanego algorytmu bazującego na regułach logicznych (minimalizującego chwilową wymianę energii elektrycznej z siecią),
2. sterowanie magazynem za pomocą algorytmu opartego na metodzie optymalizacji PSO w sposób minimalizujący koszty energii elektrycznej ponoszone przez prosumenta,
3. sterowanie magazynem za pomocą algorytmu opartego na metodzie optymalizacji PSO w sposób maksymalizujący neutralność finansową prosumenta.

Ponieważ fabrycznie zaimplementowany algorytm sterowania magazynem oparty na regułach logicznych nie posiada funkcji sterowania wybranymi odbiornikami, to w celu zachowania spójności wszystkich trzech etapów badań, również w etapach 2 i 3 ograniczono się tylko do sterowania magazynem energii (praca odbiorników SL nie podlegała planowaniu i były one załączane przez użytkowników w miarę potrzeb). W kolejnych punktach opisano wyniki uzyskane w poszczególnych etapach badań.

5.1. Sterowanie magazynem za pomocą algorytmu opartego na regułach logicznych

Pierwszy etap badań został zrealizowany w okresie od 22 do 28 czerwca 2025 roku. W tym czasie sterowanie magazynem odbywało się lokalnie, za pomocą fabrycznie zaimplementowanego algorytmu bazującego na regułach logicznych, którego celem jest minimalizacja aktualnej wymiany energii pomiędzy siecią elektroenergetyczną a budynkiem. Podczas tak realizowanego sterowania, na podstawie danych pochodzących z licznika energii elektrycznej zainstalowanego na przyłączy budynku (licznik nr 1) oraz uwzględniając aktualny stan naładowania baterii, algorytm decydował czy w danej chwili magazyn ma być ładowany nadwyżką generowanej energii lub czy ma zostać rozładowany w celu zasilenia urządzeń w budynku. Jednocześnie w tym okresie wykonywane były badania symulacyjne, których celem było wyznaczenie w poszczególnych dniach dwóch dodatkowych planów pracy magazynu, opracowanych z wykorzystaniem metody optymalizacji PSO (rozdział 3.3), realizującej dwie funkcje celu: minimalizację kosztów energii ponoszonych przez prosumenta oraz maksymalizację neutralności finansowej prosumenta. Badania symulacyjne wykonywano z wykorzystaniem prognoz zapotrzebowania bazowego i generacji PV opracowanych dla poszczególnych dni, z zastosowaniem metod opisanych w punktach 3.1 i 3.2 oraz obowiązujących cen energii elektrycznej dla tych dni, pochodzących ze strony Polskich Sieci


Elektroenergetycznych. Celem badań było porównanie wyników pomiarów z wynikami symulacji. W symulacjach założono, że odbiorniki SL pracowały w ten sam sposób jak pracowały w rzeczywistości (nie optymalizowano czasów ich załączania).

Danymi wsadowymi do symulacji przeprowadzanych dla kolejnych dni były:

1. prognozowany profil bazowego (podstawowego) zapotrzebowania na energię elektryczną rozpatrywanego odbiorcy komunalno-bytowego,
2. prognozowany profil generacji źródła fotowoltaicznego posiadanego przez rozpatrywanego prosumenta,
3. obowiązujący profil godzinowych rynkowych cen energii elektrycznej (RCE), udostępniony przez Polskie Sieci Elektroenergetyczne (PSE).

Przygotowane profile zostały wczytane do programu optymalizującego, w którym wcześniej sparametryzowany został model mikroinstalacji PV (zgodnie z opisem zamieszczonym w punkcie 3.2) oraz model magazynu energii (podano moc znamionową ładowarki, pojemność całkowitą magazynu, maksymalny stopień naładowania i rozładowania baterii oraz sprawność podczas ładowania i rozładowania zasobnika). Następnie, każdorazowo przed rozpoczęciem symulacji, zostały uzupełnione dane dotyczące stopnia naładowania magazynu o godzinie 00:00 kolejnej doby, czyli w chwili początkowej okresu symulacji. Ponieważ symulacje były wykonywane w przeddzień dnia, dla którego wyznaczone miały być profile pracy magazynu, to stan jego naładowania został wyznaczony szacunkowo (z tego wynikają różnice między wynikami pomiarów a wynikami symulacji w tym zakresie). Następnie została wybrana funkcja celu jaką algorytm miał zrealizować. W pierwszym podejściu była to funkcja realizująca minimalizację kosztów energii, a w kolejnym kroku obliczenia realizowano dla maksymalizacji neutralności finansowej prosumenta. Algorytm PSO w jednym cyklu obliczeniowym wykonywał 350 iteracji. W celu uzyskania optymalnego profilu pracy magazynu energii dla zadanych funkcji celu wykonano po dziesięć symulacji, z których wybrano te, dla których uzyskano najlepsze wyniki. Wykorzystane dane oraz uzyskane wyniki dla przykładowego dnia z rozpatrywanego okresu przedstawiono na rysunkach 5.2 – 5.9. Z kolei w tabeli 5.2 zestawiono najważniejsze wielkości charakteryzujące pracę instalacji w kolejnych dniach analizowanego okresu.

Do szczegółowego omówienia wyników badań wybrano dzień 22 czerwca 2025 r., ponieważ profil cenowy w tym dniu wyróżniał się dużą zmiennością cen, z ujemnymi cenami energii elektrycznej między godziną 9:00 a 16:00 oraz wyższymi cenami w szczycie wieczornym (rys. 5.2). Ujemne ceny były spowodowane wysoką produkcją energii elektrycznej z odnawialnych źródeł energii, zwłaszcza fotowoltaicznych, w tym dniu.




Rys. 5.2. Rynkowe ceny energii elektrycznej w dniu 22 czerwca 2025 r.

W celu porównania efektów działania fabrycznie zaimplementowanego algorytmu sterowania magazynu z proponowanym algorytmem optymalizacyjnym PSO przeprowadzone zostały dwa warianty symulacji. Jak wspomniano wcześniej, w pierwszym wariancie wyznaczano profil pracy magazynu, który minimalizował koszty energii elektrycznej, a w drugim wariancie określano profil pracy magazynu, który maksymalizował neutralność finansową prosumenta. Prognozowane profile zapotrzebowania bazowego, generacji źródła PV oraz dane dotyczące początkowego stopnia naładowania magazynu energii były identyczne dla obu przeprowadzonych optymalizacji PSO. Omówienie uzyskanych wyników podzielono na kilka etapów, opisanych poniżej.


W pierwszym kroku porównano, przyjęty w symulacjach prognozowany profil bazowego zapotrzebowania na energię elektryczną, z profilem zużycia zarejestrowanym w badanym dniu, co zostało przedstawione na rysunku 5.3 (prognozowany profil zapotrzebowania bazowego dla obydwóch funkcji celu był identyczny, a czas załączania urządzeń sterowanych nie był optymalizowany). Można zauważyć, że w początkowych godzinach doby profile prognozowany i rzeczywisty były bardzo zbliżone do siebie, natomiast w późniejszych godzinach wartości zmierzone mocniej różniły się od prognozy bazowego zapotrzebowania. Wpływ na to mieli domownicy mieszkający w badanym obiekcie, którzy poprzez załączanie różnych urządzeń wpływali na rzeczywiste wartości zużytej energii w kolejnych okresach doby. Na rys. 5.4 porównano z kolei prognozę generacji PV z rzeczywistymi danymi zarejestrowanymi w omawianym dniu. Największa różnica pomiędzy zarejestrowanymi wartościami a prognozą uwidoczniła się od godziny 11:00 do 15:00, czyli w okresie największego promieniowania słonecznego. Przyczyną tego stanu rzeczy były wyłączenia falownika spowodowane zbyt wysokim poziomem napięcia w sieci elektroenergetycznej (wzrost napięcia powyżej dopuszczalnej wartości 253 V), co ilustruje rzeczywisty profil

generacji PV zarejestrowany w rozdzielczości minutowej oraz profil napięcia zmierzonego na przyłączy rozpatrywanego budynku, przedstawione na rysunku 5.5.


a.



b.




Rys. 5.3. Porównanie prognozowanego i rzeczywistego obciążenia a) bazowego oraz b) całkowitego w dniu 22 czerwca 2025 r.




Rys. 5.4. Porównanie prognozowanej i rzeczywistej generacji źródła PV w dniu 22 czerwca 2025 r.

a.



b.



Rys. 5.5. Zarejestrowane profile a) generacji PV, b) napięcia na przyłączy w dniu 22 czerwca 2025 r.


Przedstawione powyżej dobowe profile cen energii, prognozowanego zapotrzebowania bazowego oraz generacji PV stanowią dane wejściowe do algorytmu optymalizującego działanie RESS dla obu rozpatrywanych funkcji celu. Otrzymane wyniki symulacji, obejmujące program pracy RESS oraz stan naładowania magazynu, porównano z rzeczywistymi pomiarami zrealizowanymi w tym dniu podczas pracy magazynu sterowanego fabrycznym algorytmem opartym na regułach logicznych, co przedstawiono na rysunku 5.6. Widoczne jest, że algorytm PSO realizujący minimalizację kosztów energii elektrycznej (min CE) rozładowywał magazyn energii w godzinach nocnych i porannych, celem ładowania go w okresie największej generacji

PV, gdy ceny energii elektrycznej były niskie. W tym okresie moc ładowania RESS obliczona przez algorytm PSO była znacznie większa niż moc ładowania wynikająca z pomiarów. Z kolei w okresie szczytu wieczornego magazyn oddawał znacznie większe ilości energii, ponieważ wtedy cena na rynku miała największą wartość. Sterowanie magazynem w taki sposób pozwoliłoby mu pracować w trybie ładowania w okresie największej generacji PV przez dłuższy czas w porównaniu z sytuacją, gdy magazyn był sterowany przez algorytm oparty na regułach. Należy jednak zaznaczyć, że w przypadku gdy magazyn byłby kontrolowany zgodnie z profilem minimalizującym koszty energii akumulator byłby ładowany i rozładowywany z większą mocą niż w przypadku sterowania zgodnie z profilem maksymalizującym neutralność finansową prosumenta lub według algorytmu opartego na regułach (ten tryb pracy powodował, że magazyn bardzo szybko osiągał pełne naładowanie, a następnie równie szybko rozładowywał się do poziomu minimalnego poziomu SoC). W rezultacie RESS wykonywałby pełny cykl pracy w ciągu doby, co sprzyja szybszemu zużyciu urządzenia.


Z kolei drugi wariant symulacji, który realizował maksymalizację neutralności finansowej prosumenta, przygotował profil pracy RESS w taki sposób, aby w czasie największej generacji naładować magazyn do SoC równego 100% (uprzednio go rozładowując, szczególnie w okresie gdy ceny zbliżyły się do zera) i następnie rozładowywać go w taki sposób, aby w czasie najwyższych cen energii zapotrzebowanie budynku było w całości pokryte za pomocą zgromadzonej w magazynie energii pochodzącej z generacji PV. Działanie RESS zgodnie z tym profilem skutkowało wolniejszymi zmianami SoC i wykonaniem w ciągu doby niepełnego cyklu pracy, co powinno wydłużyć żywotność baterii w stosunku do sytuacji, w której magazyn byłby sterowany według minimalizacji kosztów energii.

Wymiernym efektem optymalizacji RESS była zmiana poziomu autokonsumpcji generowanej energii w porównaniu z sytuacją, gdy magazyn był kontrolowany przez algorytm oparty na regułach. Zostało to pokazane na rysunku 5.7. Dla profilu pracy magazynu uzyskanego w wyniku maksymalizacji neutralności finansowej prosumenta widoczny jest znaczący wzrost autokonsumpcji w ciągu rozpatrywanej doby. Zużycie własne wprawdzie spadło w okresie od 8 rano do 10 oraz po południu od godziny 16 do 17, ale w pozostałych godzinach było wyższe w stosunku do pomiarów. W tym przypadku dzienne zużycie własne wzrosło z 40,1% (wartość uzyskana podczas sterowania magazynem opartym na fabrycznie zaimplementowanym algorytmie) do 51,2%, gdy sterowania RESS odbywałoby się według profilu maksymalizującego neutralność finansową prosumenta. Z kolei dla profilu pracy RESS minimalizującego koszty energii zaobserwowano zmniejszenie autokonsumpcji, która osiągnęła w ciągu całej doby poziom 30,1%.


a.



b.




Rys. 5.6. Porównanie zmierzonych i uzyskanych z symulacji PSO profili a) mocy i b) stopnia naładowania magazynu w dniu 22 czerwca 2025 r.




Rys. 5.7. Autokonsumpcja generowanej energii pochodzącej ze źródła PV wynikająca z pomiarów i ze zoptymalizowanych profili pracy magazynu dniu 22 czerwca 2025 r.

Zmiana poziomu zużycia własnego (autokonsumpcji) wpływa na wymianę energii z siecią dystrybucyjną nN, co zostało zilustrowane na rysunku 5.8. Po zastosowaniu algorytmu PSO minimalizującego koszt (min CE) zaobserwowano wzrost wymiany energii z siecią dystrybucyjną, natomiast dla maksymalizacji neutralności finansowej (max NF) wartość dobowej wymiany z siecią zmniejszyła się, w porównaniu do wartości rzeczywistych, wynikających z pomiarów przeprowadzonych przy pracy magazynu sterowanego algorytmem opartym na regułach logicznych. Dla pracy magazynu minimalizującego koszt energii (min CE)

eksport energii do sieci wystąpił przez większość doby, osiągając największe wartości w godzinach z najwyższymi cenami energii. Z kolei w godzinach z najniższymi (ujemnymi) cenami energii, nastąpił pobór energii z sieci, co skutkuje odnośnieniem dodatkowego przychodu przez prosumenta. Uzyskany efekt kosztowy zilustrowano na rys. 5.9. W przypadku gdy magazyn pracowałby w sposób maksymalizujący neutralność finansową prosumenta wymiana z siecią byłaby najmniejsza spośród analizowanych wariantów sterowania. Zastosowanie takiej funkcji celu spowodowałoby, że w tym dniu prosument nie poniósłby praktycznie żadnych kosztów, gdyż import energii z sieci wyniósłby jedynie 0,6 kWh. Jednocześnie przy eksporcie równym 12,4 kWh prosument uzyskałby jedynie minimalny przychód, ponieważ w czasie, w którym ten eksport miałby miejsce ceny energii były bliskie zero. W rezultacie tego dnia osiągnięto by wysoką neutralność finansową, co przedstawiono na rys. 5.9.



Rys. 5.8. Profile wymiany energii z siecią elektroenergetyczną w dniu 22 czerwca 2025 r.



Rys. 5.9. Koszty (wartości dodatnie) i przychody (wartości ujemne) prosumenta obliczone na podstawie wymiany energii z siecią elektroenergetyczną wynikającej z pomiarów oraz ze sterowania magazynem według dwóch różnych funkcji celu w dniu 22 czerwca 2025 r.

Podsumowanie wyników analiz wykonanych dla omawianego dnia przedstawiono w tabeli 5.2, w której zestawiono również wyniki uzyskane dla kolejnych dni rozpatrywanego okresu. Podsumowując otrzymane rezultaty badań można przede wszystkim zauważyć, że:

1. uzyskano stosunkowo wysoką dokładność prognozy dobowego obciążenia bazowego i generacji PV (w porównaniu z wartościami zmierzonymi); maksymalna różnica między dobowym zapotrzebowaniem prognozowanym a rzeczywistym wyniosła 15,8%, natomiast w przypadku generacji PV było to 13,7%,
2. w analizowanym tygodniu średni rzeczywisty poziom autokonsumpcji wyniósł 38,97%; z kolei otrzymane w symulacjach średnie wartości tego wskaźnika wynoszą 28,64% dla minimalizacji kosztów energii oraz 58,26% dla maksymalizacji neutralności finansowej prosumenta,
3. w każdym przypadku sterowania magazynem tygodniowy import energii z sieci był niższy niż eksport energii do sieci, co wynika z przewagi sumarycznej generacji PV nad zapotrzebowaniem budynku w tym okresie; w rozpatrywanym tygodniu rzeczywisty (zmierzony) import energii wyniósł 13,7 kWh, natomiast eksport wyniósł 107,2 kWh; podczas symulacji wykonanych dla minimalizacji kosztów energii wymiana z siecią była największa (tygodniowy import wyniósł 55,9 kWh, przy eksporcie równym 190,3 kWh); z kolei dla symulacji maksymalizujących neutralność finansową prosumenta z sieci pobrano 12,8 kWh a oddano 59,1 kWh, co oznacza najmniejszą wymianę energii z siecią spośród trzech przeanalizowanych strategii sterowania pracą magazynu,
4. gdyby do rozliczeń zastosować rynkowe ceny energii, to w badanym okresie prosument uzyskałby sumaryczny przychód w wysokości 2,29 zł; znacznie wyższy sumaryczny przychód (78,11 zł) w tym okresie prosument osiągnąłby, gdyby magazyn energii był sterowany według profilu minimalizującego koszty energii; z kolei podczas sterowania magazynem w sposób maksymalizujący neutralność finansową prosument poniósłby koszt równy 3,54 zł.


Tabela 5.2

Zestawienie wyników badań dla okresu, w którym magazyn był sterowany algorytmem opartym na regułach logicznych

Oceniana wielkość	Jednostka	Typ pomiaru	Data						
			22.06.2025	23.06.2025	24.06.2025	25.06.2025	26.06.2025	27.06.2025	28.06.2025
Generacja PV	kWh	Prognoza	32,3	23,9	27,2	26,0	29,1	19,4	28,9
		Rzeczywisty	29,4	28,4	30,9	26,6	33,7	20,8	31,8
Obciążenie	kWh	Prognoza	15,7	15,4	18,6	18,4	20,1	16,6	16,4
		Rzeczywisty	16,3	16,1	21,4	17,6	19,7	14,6	16,6
Import energii	kWh	Rzeczywisty	0,8	1,6	5,0	2,5	1,6	1,1	1,1
		Symulacja – min CE	7,0	11,9	7,2	8,5	3,3	12,5	5,5
		Symulacja – max FN	0,6	1,2	3,5	3,1	2,4	1,4	0,6
Eksport energii	kWh	Rzeczywisty	15,6	15,0	16,2	14,5	17,2	8,1	20,6
		Symulacja – min CE	32,0	31,9	26,3	26,9	22,2	24,6	26,4
		Symulacja – max FN	12,4	8,9	10,0	9,3	8,1	1,6	8,8
Ładowanie RESS	kWh	Rzeczywisty	4,9	4,9	4,7	3,8	6,1	5,1	3,8
		Symulacja – min CE	19,7	19,1	19,5	19,3	14,4	18,3	19,5
		Symulacja – max FN	17,0	10,0	13,7	9,4	11,6	9,2	14,2
Rozładowanie RESS	kWh	Rzeczywisty	5,9	5,9	6,5	7,5	7,6	5,9	8,1
		Symulacja – min CE	28,8	30,6	30,0	29,5	24,3	27,6	27,8
		Symulacja – max FN	12,8	9,2	11,6	7,5	8,3	6,6	9,9
Początkowy SoC	%	Rzeczywisty	77	87	80	89	70	83	82
		Symulacja – min CE	81	93	89	86	83	80	77
		Symulacja – max FN	81	93	89	86	83	80	77
Końcowy SoC	%	Rzeczywisty	87	80	89	70	83	82	83
		Symulacja – min CE	25	22	25	23	20	22	21
		Symulacja – max FN	86	84	85	83	86	81	84
Autokonsumpcja	%	Rzeczywisty	40,1	35,5	40,5	40,2	41,1	45,6	29,8
		Symulacja – min CE	30,1	23,0	30,9	27,4	29,4	28,5	31,2
		Symulacja – max FN	51,2	59,5	62,0	58,0	50,4	63,9	62,8
Koszt energii	PLN	Rzeczywisty	1,73	-1,11	2,39	1,14	-3,97	-0,61	-1,86
		Symulacja – min CE	-12,87	-11,79	-9,48	-11,38	-11,94	-10,13	-10,52
		Symulacja – max FN	-0,15	0,19	1,45	2,09	-0,51	0,42	0,05

5.2. Sterowanie magazynem za pomocą algorytmu opartego na metodzie optymalizacji w sposób minimalizujący koszty energii elektrycznej


W tym punkcie opisano wyniki badań polegających na wyznaczeniu planu pracy magazynu w sposób minimalizujący dobowy koszt energii elektrycznej ponoszony przez prosumenta, a następnie sterowaniu magazynem według tak opracowanego planu. Podobnie jak poprzednio, badania obejmowały okres jednego tygodnia, a zrealizowano je w okresie od 10 do 16 lipca 2025 r. Symulacje dobowe każdorazowo rozpoczęto od przygotowania prognozowanych profili generacji PV i zapotrzebowania bazowego budynku oraz uzupełnienia informacji o przewidywanym początkowym stanie naładowania magazynu. Proces przygotowania danych wejściowych był identyczny jak ten opisany w punkcie 5.1. Do szczegółowego zobrazowania uzyskanych wyników badań wybrano dzień 14 lipca 2025 r., cechujący się wysokim zróżnicowaniem cen energii. W tym dniu ceny w godzinach 00:00 a 18:00 charakteryzowały się zmianami o około 0,20 zł/kWh, natomiast podczas wieczornego szczytu zapotrzebowania ceny były ponad dwukrotnie wyższe od średniej dobowej, co przedstawiono na rys. 5.10.




Rys. 5.10. Rynkowe ceny energii elektrycznej w dniu 14 lipca 2025 r.

Podobnie jak w rozdziale 5.1, na początku omawiania uzyskanych wyników dla wybranego dnia porównano zarejestrowane dane pomiarowe dotyczące zapotrzebowania budynku z prognozą, co zostało przedstawione na rysunku 5.11. Czas załączania urządzeń sterowanych, podobnie jak w badaniach przedstawionych w pkt. 5.1, nie był optymalizowany. Można zaobserwować, że zarejestrowane wartości zapotrzebowania budynku w początkowych i końcowych godzinach doby oraz w okresie od 12:00 do 15:00 są bardzo zbliżone do prognozowanego profilu bazowego zapotrzebowania. W pozostałych godzinach zarejestrowane wartości różnią się od tych zawartych w prognozie, co było spowodowane zachowaniem użytkowników w badanym obiekcie i załączaniem różnych sprzętów AGD w ciągu doby.

a.




b.



Rys. 5.11. Porównanie obciążenia a) bazowego oraz b) całkowitego w dniu 14 lipca 2025 r.


Na rysunku 5.12 została z kolei porównana prognoza generacji w źródle PV z rzeczywistymi danymi. Widocznym jest, że rzeczywisty profil generacji był podobny do profilu prognozowanego w początkowych i końcowych godzinach generacji źródła PV. Znaczące różnice pojawiły się natomiast w okresie od godziny 12:00 do 14:00, co spowodowane było opadami deszczu (według prognozy opady te były przewidziane od 15:00 do 16:00, stąd rozbieżność prognozy od jej realizacji).



Rys. 5.12. Porównanie generacji źródła PV w dniu 14 lipca 2025 r.

Przedstawione wyżej dobowe profile cen energii i prognozy zapotrzebowania bazowego oraz generacji PV stanowią dane wejściowe do algorytmu optymalizującego RESS, w tym


przypadku minimalizującego koszty energii elektrycznej. Uzyskany w wyniku obliczeń optymalizacyjnych program pracy magazynu został następnie wykorzystany do sterowania pracą tego urządzenia, czyli rzeczywisty profil pracy magazynu był identyczny jak ten wyznaczony przez algorytm PSO, co pokazano na rys. 5.13.a. Rzeczywisty profil przedstawiający stan naładowania magazynu jest bardzo podobny do profilu wyznaczonego przez algorytm optymalizacyjny, co przedstawione zostało na rysunku 5.13.b. Występujące różnice między tymi profilami są spowodowane rozbieżnością między rzeczywistym, a przyjętym do obliczeń początkowym stopniem naładowania magazynu, a także niedoskonałością modelu magazynu wykorzystanego w symulacjach.



Rys. 5.13. Porównanie rzeczywistych profili a) mocy magazynu i b) stopnia naładowania z wynikami uzyskanymi w procesie optymalizacji PSO w dniu 14 lipca 2025 r.


Praca RESS według zadanego programu wpłynęła na poziom autokonsumpcji generowanej energii, co zostało przedstawione na rysunku 5.14. Na tym rysunku widoczne jest, iż w okresach od 7:00 do 9:00, 15:00 do 16:00 oraz 17:00 do 18:00 rzeczywisty poziom autokonsumpcji był o wiele niższy od przewidywanego współczynnika dla wyznaczonego symulacyjnie profilu pracy magazynu. Odwrotna sytuacja miała natomiast miejsce w godzinach od 12:00 do 14:00 oraz od 16:00 do 17:00, kiedy rzeczywisty poziom autokonsumpcji był wyższy od przewidywanego. Rzeczywiste dzienne zużycie własne dla tego dnia wyniosło 26,9% i było niższe od wartości wyznaczonych w symulacjach, które wynosiło 32,6%.

Otrzymane rozbieżności wynikają głównie z różnic między prognozami zużycia i generacji, a ich rzeczywistymi realizacjami.




Rys. 5.14. Autokonsumpcja generowanej energii pochodzącej ze źródła PV wynikająca z pomiarów i symulacji w dniu 14 lipca 2025 r.

Poziom autokonsumpcji każdorazowo pływa na wymianę energii z siecią elektroenergetyczną (rys. 5.15), a ilość oddanej i pobranej energii ma swoje odzwierciedlenie finansowe dla prosumenta (rys. 5.16). W wybranym dniu (14 lipca) magazyn został wystawiony w taki sposób, aby w okresie najwyższych cen energii, eksportować energię do systemu i tym samym generować przychód. Wartości rzeczywistej wymiany energii z siecią elektroenergetyczną pozwoliły wygenerować przychód w wysokości 8,96 zł, który jest wyższy od uzyskanego w symulacjach (7,13 zł). Zestawienie wyników badań dla funkcji celu minimalizującej koszty energii dla poszczególnych dni analizowanego tygodnia przedstawiono w tabeli 5.3.



Rys. 5.15. Profile wymiany energii z siecią elektroenergetyczną w dniu 14 lipca 2025 r.



Rys. 5.16. Koszt (wartości dodatnie) i przychód (wartości ujemne) prosumenta obliczone na podstawie zmierzonej i uzyskanej w symulacjach wymiany energii z siecią elektroenergetyczną w dniu 14 lipca 2025 r.

Podsumowując zaprezentowane w tabeli 5.3 wyniki można przede wszystkim zauważyć, że:

1. w porównaniu z wartościami zmierzonymi, prognozy dobowego obciążenia bazowego i dobowej generacji PV dla kilku dni osiągnęły bardzo dobre dopasowanie, co przekłada się na różnicę między prognozą a jej realizacją wynoszącą około 5%; pomimo ogólnie poprawnych prognoz w tym okresie, w dniu 13.07.2025 r. maksymalna różnica między dobowym prognozowanym zapotrzebowaniem a rzeczywistym pomiarem wyniosła 35,2%; z kolei w przypadku generacji PV maksymalna różnica wyniosła 30,8% i wystąpiła w dniu 11.07.2025 r.,
2. przy pracy magazynu według profilu minimalizującego koszty energii średni rzeczywisty poziom autokonsumpcji w analizowanym tygodniu wyniósł 36,90% i był niższy niż uzyskany w symulacjach (42,29%),
3. tygodniowy rzeczywisty import energii z sieci elektroenergetycznej wyniósł 39,1 kWh i był wyższy od przewidywanego (30,3 kWh); z kolei rzeczywisty eksport wyniósł 83,9 kWh i również był wyższy od wyznaczonego przez algorytm optymalizacyjny PSO (71,1 kWh); uzyskane różnice pomiędzy tymi wartościami wynikają głównie z rozbieżności prognozowanej i rzeczywistej generacji energii w źródle PV oraz zapotrzebowania na energię elektryczną w budynku,
4. sumaryczne rzeczywiste przychody prosumenta dla tego okresu wyniosłyby 25,02 zł, co jest wartością wyższą niż przewidywany przychód wyznaczony przez algorytm PSO, który wyniósł 20,49 zł.

Tabela 5.3


Zestawienie wyników badań dla okresu, w którym magazyn był sterowany w sposób minimalizujący koszty energii elektrycznej ponoszone przez prosumenta

Oceniana wielkość	Jednostka	Typ pomiaru	Data						
			10.07.2025	11.07.2025	12.07.2025	13.07.2025	14.07.2025	15.07.2025	16.07.2025
Generacja PV	kWh	Prognoza	22,7	21,2	15,8	23,8	29,1	25,3	29,7
		Rzeczywisty	22,8	16,2	18,4	25,0	29,4	23,1	30,7
Obciążenie	kWh	Prognoza	15,4	15,4	16,3	16,9	16,1	16,2	17,6
		Rzeczywisty	14,0	14,9	13,5	12,5	14,0	15,3	17,7
Import energii	kWh	Rzeczywisty	7,8	2,8	3,1	10,0	2,9	7,7	4,8
		Symulacja – min CE	6,9	0,6	3,6	13,8	0,2	4,4	0,8
Eksport energii	kWh	Rzeczywisty	12,3	4,8	6,7	14,2	17,7	11,2	17,0
		Symulacja – min CE	11,8	7,2	1,7	12,5	12,6	13,4	11,9
Ładowanie RESS	kWh	Rzeczywisty	14,3	8,1	6,7	19,2	13,1	13,3	13,7
		Symulacja – min CE	14,3	8,1	6,7	19,2	13,1	13,3	13,7
Rozładowanie RESS	kWh	Rzeczywisty	10,9	8,8	5,3	11,1	12,5	11,2	12,8
		Symulacja – min CE	10,9	8,8	5,3	11,1	12,5	11,2	12,8
Początkowy SoC	%	Rzeczywisty	10	30	10	13	37	20	21
		Symulacja – min CE	10	30	18	20	40	15	34
Końcowy SoC	%	Rzeczywisty	30	10	13	38	20	21	15
		Symulacja – min CE	19	14	13	22	18	33	41
Autokonsumpcja	%	Rzeczywisty	45,8	46,5	37,5	33,4	26,9	40,0	28,2
		Symulacja – min CE	46,4	44,0	56,5	39,4	32,6	43,3	33,8
Koszt energii	PLN	Rzeczywisty	3,94	-1,08	-1,81	-4,97	-8,96	-5,04	-7,10
		Symulacja – min CE	3,10	-3,18	0,71	-3,38	-7,13	-4,81	-5,80

5.3. Sterowanie magazynem za pomocą algorytmu opartego na metodzie optymalizacji w sposób maksymalizujący neutralność finansową prosumenta

Podobnie jak badania opisane w punktach 5.1 oraz 5.2, również trzeci etap badań był realizowany w okresie jednego tygodnia (w okresie od 17 do 23 lipca 2025 r.). W tych dniach magazyn energii realizował, wyznaczony przez algorytm optymalizacyjny PSO, plan pracy maksymalizujący neutralność finansową prosumenta. Plan ten został przygotowany z wykorzystaniem analogicznych danych, jak opisane w poprzednich punktach.


Do omówienia wyników badań wybrano dzień 19 lipca 2025 r. W tym dniu ceny energii od godziny 00:00 do 9:00 charakteryzowały się nieznacznymi zmianami. W kolejnym okresie, od godziny 9:00 do 15:00, ceny wyraźnie spadły i nie przekraczały wartości 0,20 zł/kWh. Najwyższa cena energii, w wieczornym szczycie zapotrzebowania, wynosiła około 0,6 zł/kWh. Dobowy profil cenowy dla tego dnia został przedstawiony na rysunku 5.17.




Rys. 5.17. Rynkowe ceny energii elektrycznej w dniu 19 lipca 2025 r.

Porównanie zarejestrowanego profilu zapotrzebowania budynku w wybranym do szczegółowej analizy dniu z prognozą przedstawiono na rysunku 5.18. Czas załączania urządzeń sterowanych, podobnie jak w badaniach przedstawionych w pkt. 5.1 i 5.2, nie był optymalizowany. Na wykresie można zaobserwować, że zarejestrowane wartości mocy w budynku w początkowych godzinach doby są bardzo zbliżone do prognozowanego profilu zapotrzebowania bazowego, natomiast w ciągu kolejnych godzin doby wartości te różnią się od siebie znacząco. Istotny wpływ na taki stan miał m.in. odbiornik sterowany, który pracował od 8.00 a 11.00 oraz między godzinami 13:00 i 14:00.

a.




b.




Rys. 5.18. Porównanie obciążenia a) bazowego oraz b) całkowitego w dniu 19 lipca 2025 r.

Kolejny rysunek (5.19) przedstawia porównanie prognozy generacji PV z rzeczywistymi danymi dotyczącymi produkcji energii w mikroinstalacji w analizowanym dniu. Kształt profilu rzeczywistej generacji był podobny do profilu z prognozy w początkowych i końcowych godzinach pracy źródła PV. Znaczące różnice pojawiły się w okresie od godziny 12:00 do 14:00, co spowodowane było zbyt wysokim poziomem napięcia w sieci w tym przedziale czasowym, skutkującym okresowymi wyłączeniami falownika. Również w okresach od 9:00 do 12:00 oraz 14:00 do 18:00 zaobserwować można różnice między prognozą a jej realizacją, przy czym w tym przypadku rzeczywista generacja w źródle PV była wyższa niż ta, którą przyjęto do obliczeń optymalizacyjnych.




Rys. 5.19. Porównanie generacji źródła PV w dniu 19 lipca 2025 r.

Wykorzystując przedstawione dane wejściowe wyznaczono program pracy magazynu, który maksymalizuje neutralność finansową prosumenta w ciągu doby. Został on zaprezentowany na rys. 5.20.a, a następnie bezpośrednio wykorzystany do sterowania pracą zasobnika. W wyniku pracy magazynu zmianie ulegał jego dobowy stopień naładowania, co pokazano z kolei na rys. 5.20.b. Występujące różnice wynikały przede wszystkim z innego początkowego stanu naładowania magazynu w rzeczywistości, w stosunku do przyjętego w symulacjach oraz niepełne odwzorowanie rzeczywistych właściwości magazynu w jego modelu.




Rys. 5.20. Porównanie rzeczywistych profili a) mocy magazynu i b) stopnia naładowania z wynikami uzyskanymi w procesie optymalizacji PSO w dniu 19 lipca 2025 r.

W początkowych godzinach doby rzeczywisty poziom autokonsumpcji był wyższy od wyznaczonego przez algorytm optymalizacyjny podczas symulacji i w miarę upływu czasu stopniowo się zmniejszał, co pokazuje rys. 5.21. Największe różnice w autokonsumpcji rzeczywistej i wyznaczonej podczas symulacji miały wynosić około 20%. Rzeczywiste dzienne zużycie własne dla tego dnia wyniosło 46,8% i było zbliżone do wartości wyznaczonych przez algorytm optymalizacyjny PSO (48,2%).




Rys. 5.21. Autokonsumpcja generowanej energii pochodzącej ze źródła PV wynikająca z pomiarów i symulacji w dniu 19 lipca 2025 r.

Uzyskaną wymianę energii z siecią dystrybucyjną w omawianym dniu przedstawia rysunek 5.22. W początkowych godzinach doby zmierzony profil wymiany miał kształt zbliżony do profilu przygotowanego przez algorytm optymalizacyjny. W kolejnych godzinach widoczne są większe różnice pomiędzy rzeczywistą wymianą energii z siecią, a profilem wyznaczonym przez algorytm optymalizacyjny, co wynika przede wszystkim z wartości generowanej energii w źródle PV. Pokazane na rys. 5.22 wartości rzeczywistej wymiany energii z siecią elektroenergetyczną wygenerowałyby przychód w wysokości 1,65 zł, który jest nieco mniejszy od przychodu przewidywanego w symulacjach (2,04 zł). Uzyskiwane w kolejnych godzinach przychody i koszty prosumenta zostały przedstawione na rysunku 5.23. Zestawienie wyników badań dla funkcji celu maksymalizującej neutralność finansową prosumenta w ciągu całego tygodnia przedstawiono w tabeli 5.4.



Rys. 5.22. Profile wymiany energii z siecią elektroenergetyczną w dniu 19 lipca 2025 r.



Rys. 5.23. Koszt (wartości dodatnie) i przychód (wartości ujemne) prosumenta obliczone na podstawie zmierzonej i uzyskanej w symulacjach wymiany energii z siecią elektroenergetyczną w dniu 19 lipca 2025 r.

Podsumowując zaprezentowane w tabeli 5.4 wyniki można przede wszystkim zauważyć, że:

1. ponownie uzyskano stosunkowo dobrą dokładność prognozy dobowego obciążenia bazowego i generacji PV (w porównaniu z wartościami zmierzonymi); maksymalna różnica między prognozowanym dobowym zapotrzebowaniem a rzeczywistym wyniosła 20,2%, a w przypadku generacji PV maksymalna różnica wynosiła 23,2%,
2. przy pracy magazynu według profilu maksymalizującego neutralność finansową prosumenta średni rzeczywisty poziom autokonsumpcji w analizowanym tygodniu wyniósł 50,46% i był niższy niż uzyskany podczas symulacji (57,69%),
3. tygodniowy rzeczywisty import energii wyniósł 27,2 kWh i był wyższy od wyznaczonego symulacyjnie (11,1 kWh); z kolei rzeczywisty eksport energii wyniósł 53,2 kWh i również był wyższy od wyznaczonego przez algorytm PSO (34,9 kWh); podobnie jak w poprzednich cyklach badań, różnica pomiędzy wartościami zmierzonymi a obliczonymi wynika głównie z różnic między prognozami, a rzeczywistą generacją energii w źródle PV i zapotrzebowaniem budynku,
4. sumaryczne rzeczywiste przychody prosumenta dla tego okresu wyniosłyby 7,02 zł, co jest wartością wyższą niż przewidywany przychód wyznaczony przez algorytm PSO, który wyniósł 3,84 zł.

Tabela 5.4

Zestawienie wyników badań dla okresu, w którym magazyn był sterowany w sposób maksymalizujący neutralność finansową prosumenta

Oceniana wielkość	Jednostka	Typ pomiaru	Data						
			17.07.2025	18.07.2025	19.07.2025	20.07.2025	21.07.2025	22.07.2025	23.07.2025
Generacja PV	kWh	Prognoza	21,8	24,8	30,1	25,4	30,8	25,2	26,4
		Rzeczywisty	17,7	26,7	34,4	32,7	29,8	31,0	24,5
Obciążenie	kWh	Prognoza	14,2	18,3	17,0	15,7	15,8	16,0	16,4
		Rzeczywisty	13,6	17,6	21,3	19,6	12,4	14,8	16,6
Import energii	kWh	Rzeczywisty	7,7	7,6	2,9	1,9	1,1	4,3	1,7
		Symulacja – max FN	2,4	3,1	0,1	0,6	0,1	4,2	0,6
Eksport energii	kWh	Rzeczywisty	1,8	5,5	12,7	11,2	14,7	1,4	5,9
		Symulacja – max FN	0,0	0,0	9,9	6,4	11,4	0,2	7,0
Ładowanie RESS	kWh	Rzeczywisty	13,7	16,3	10,3	11,8	14,4	16,4	10,5
		Symulacja – max FN	13,7	16,3	10,3	11,8	14,4	16,4	10,5
Rozładowanie RESS	kWh	Rzeczywisty	3,7	5,9	7,0	8,0	10,7	3,2	6,9
		Symulacja – max FN	3,7	5,9	7,0	8,0	10,7	3,2	6,9
Początkowy SoC	%	Rzeczywisty	21	68	84	80	82	81	83
		Symulacja – max FN	15	40	80	80	80	70	80
Końcowy SoC	%	Rzeczywisty	14	84	80	82	81	83	3
		Symulacja – max FN	53	79	83	85	84	65	84
Autokonsumpcja	%	Rzeczywisty	60,0	54,2	46,8	52,5	41,8	52,4	45,5
		Symulacja – max FN	66,7	66,6	48,2	60,2	45,3	65,7	51,1
Koszt energii	PLN	Rzeczywisty	2,67	1,11	-1,65	-0,87	-6,08	-0,56	-1,64
		Symulacja – max FN	1,04	1,53	-2,04	0,05	-4,59	1,66	-1,49

6. PODSUMOWANIE I NAJWAŻNIEJSZE WNIOSKI

W pracy przedstawiono system HEMS pozwalający na zarządzanie energią u odbiorcy indywidualnego wyposażanego w źródło PV, magazyn energii elektrycznej oraz odbiorniki o elastycznym czasie załączania i znanym profilu poboru energii. Do wyznaczenia programu pracy magazynu energii oraz czasu załączania wybranych odbiorników zaprojektowany system HEMS stosuje model optymalizacyjny, realizujący zadaną funkcję celu z wykorzystaniem algorytmu PSO, a danymi wejściowymi są prognozowane profile generacji PV i bazowego zapotrzebowania budynku oraz profil cen energii elektrycznej na dany dzień. Opracowany system został wdrożony w praktyce w typowym budynku jednorodzinnym i posłużył do zrealizowania badań, których celem była ocena efektów jego działania w rzeczywistym środowisku pracy. W pierwszym etapie badań minimalizowane były koszty energii elektrycznej ponoszone przez prosumenta, natomiast w drugim etapie realizowana była funkcja mająca na celu zwiększenie poziomu neutralności finansowej tego prosumenta. W przeprowadzonych badaniach wzięto pod uwagę ograniczenia techniczne rzeczywistego zasobnika energii oraz parametry dotyczące aktualnego poziomu jego naładowania. Wykonano również badania porównawcze, w których magazyn energii był sterowany za pomocą fabrycznie zaimplementowanego algorytmu bazującego na regułach logicznych, którego celem jest minimalizacja bieżącej wymiany energii z siecią elektroenergetyczną.

Przedstawione w pracy wyniki prac teoretycznych oraz badań praktycznych zrealizowanych w rzeczywistym układzie zasilania odbiorcy indywidualnego (prosumenta) pozwalają na sformułowanie następujących wniosków końcowych:

1. Generacja energii w źródle PV zależy od wielu czynników, obejmujących m.in. kąt nachylenia paneli i ich orientację względem kierunku południowego, ale przede wszystkim od natężenia promieniowania słonecznego docierającego do powierzchni modułów PV. W ramach wykonanych prac opracowano metodę krótkoterminowego prognozowania generacji źródła fotowoltaicznego bazującą na numerycznych prognozach pogody, z wykorzystaniem modelu źródła PV wchodzącego w skład pakietu OpenDSS. Przeprowadzone badania wskazują, że opracowana metoda cechuje się dokładnością wystarczającą do zastosowania jej wyników w systemie HEMS.
2. Generacja źródła PV zależy również od temperatury modułów fotowoltaicznych, która wynika z aktualnych warunków atmosferycznych i ulega silnym wahaniom wraz z ich zmianami. Celem poprawy jakości prognozowania generacji konieczne jest właściwe odwzorowanie zmienności temperatury paneli. W ramach zrealizowanych prac

opracowany został dynamiczny model temperaturowy, pozwalający na dokładniejsze uwzględnienie zmienności temperatury paneli PV pracujących w zmiennych warunkach atmosferycznych. Badania przeprowadzone na pracujących instalacjach fotowoltaicznych potwierdziły, że w przypadku zastosowania tego modelu uzyskane wyniki obliczeń są bliższe rzeczywistości, niż wyniki otrzymywane z wykorzystaniem opisanych w literaturze modeli empirycznych. Zatem zastosowanie opracowanego modelu umożliwi dokładniejsze oszacowanie ilości wygenerowanej energii elektrycznej w określonych warunkach pogodowych.

3. W celu wyznaczenia profilu pracy magazynu energii oraz czasu załączania odbiorników sterowanych, oprócz prognozy generacji mikroinstalacji PV, niezbędna jest również prognoza bazowego profilu zapotrzebowania na energię elektryczną danego odbiorcy (prosumenta). Realizując zaplanowane prace badawcze zaproponowano metodę prognozowania zapotrzebowania odbiorcy komunalno-bytowego opartą na idei metody naiwnej, która do obliczeń wykorzystuje pomiary zużycia energii z kilku takich samych dni poprzedzających. Przedstawiony model został poddany odpowiedniej kalibracji, a następnie walidacji z wykorzystaniem danych pomiarowych rejestrowanych u odbiorcy komunalno-bytowego. Opracowany model dał błędy porównywalne z innymi, bardziej zaawansowanymi modelami, a dzięki jego prostocie istnieje możliwość jego praktycznej implementacji w systemie HEMS.
4. Zastosowanie do opracowania profilu pracy magazynu energii systemu HEMS opartego na metodzie optymalizacji i realizującego różne funkcje celu daje odmienne efekty. W przypadku maksymalizacji neutralności finansowej prosumenta magazyn jest sterowany w taki sposób, aby w jak największym stopniu pokryć zapotrzebowanie danego odbiorcy za pomocą energii pochodzącej z jego źródła PV (bieżącą produkcją lub energią zgromadzoną w zasobniku). Z kolei w wyniku zastosowania jako funkcji celu minimalizacji kosztów energii algorytm dąży do jak najszybszego naładowania magazynu w okresie niskich cen energii (również kosztem zakupu energii z sieci), a następnie jego rozładowania w czasie, gdy ceny energii są wysokie. Oznacza to, że przy sposobie sterowania minimalizującym koszty energii zmiany stopnia naładowania magazynu są szybsze i głębsze, niż w przypadku maksymalizacji neutralności finansowej prosumenta, co będzie miało wpływ na szybszą degradację urządzenia.
5. Sterowanie magazynem w sposób maksymalizujący neutralność finansową prosumenta charakteryzuje się najwyższym współczynnikiem autokonsumpcji energii generowanej w źródle PV, w porównaniu do fabrycznie zaimplementowanego algorytmu bazującego

na regułach logicznych oraz do algorytmu opartego na metodzie optymalizacji PSO, realizującego minimalizację kosztów energii elektrycznej. Oznacza to, że przy takim sposobie pracy magazynu wymiana energii z siecią jest najmniejsza, dzięki czemu zmniejsza się negatywny wpływ prosumenta na pracę systemu elektroenergetycznego.

6. Przedstawione w pracy wyniki badań potwierdzają, że przy zastosowaniu odpowiedniej funkcji celu (maksymalizacji neutralności finansowej prosumenta), opracowany system HEMS umożliwił zwiększenie poziomu autokonsumpcji energii generowanej w źródle PV, w porównaniu do fabrycznie zaimplementowanego systemu sterowania magazynem opartym na regułach logicznych. Zatem opracowany system może stanowić wyznacznik do wdrożenia systemów HEMS w nowoprojektowanych oraz istniejących instalacjach wyposażonych w źródła fotowoltaiczne, magazyny energii oraz odbiorniki o elastycznym czasie załączania, a jego zastosowanie przyczyni się do poprawy warunków pracy sieci elektroenergetycznej, zmniejszając presję na jej rozbudowę.
7. Opisany system HEMS został zbudowany jest na bazie mikrokomputera Raspberry Pi i otwartej platformy Home Assistant, co pozwala na jego lokalne działanie. System posiada jednak również możliwość zdalnego dostępu, co umożliwia wykorzystanie jego funkcjonalności z dowolnego miejsca. Zatem zewnętrzny dostęp do wybranych funkcji sterowania, np. programowania pracy magazynu, mógłby zostać udostępniony podmiotom zewnętrznym, np. operatorowi systemu dystrybucyjnego, który po zawarciu odpowiedniej umowy z prosumentem miałby możliwość zarządzania tym urządzeniem w procesie sterowania pracą sieci elektroenergetycznej na danym obszarze.
8. Opracowany system HEMS jest elastycznym rozwiązaniem, umożliwiającym zarządzanie energią w budynkach różnego rodzaju. Może on być wdrożony zarówno w nowo budowanych obiektach, jak i obiektach już istniejących. Wdrożenie opracowanego systemu HEMS na szerszą skalę przyczyni się do rozwoju idei sieci inteligentnej (ang. smart grid), w której sterowanie pracą instalacjami zasilającymi poszczególnych prosumentów odbywa się w sposób automatyczny, prowadząc jednocześnie do minimalizacji ich wpływu na działanie systemu elektroenergetycznego.

7. BIBLIOGRAFIA

Wymienione poniżej pozycje literaturowe zostały bezpośrednio przywołane w tekście autoreferatu. Uzupełnienie spisu literatury wykorzystanej podczas realizacji pracy doktorskiej stanowią pozycje cytowane w poszczególnych artykułach naukowych stanowiących rozprawę doktorską.

1. PTPiREE: Mikroinstalacje w Polsce. ptpiree.pl/energetyka-w-polsce/energetyka-w-liczbach/mikroinstalacje-w-polsce (2025.07.12)
2. Wójcicki R.: Autokonsumpcja energii elektrycznej w prosumenckiej ochronie kontrolnej, *Rynek Energii*, 1, 2020
3. Watson, J.D., Watson, N.R., Santos-Martin, D., Wood, A.R., Lemon, S. and Miller, A.J.: Impact of Solar Photovoltaics on the Low-Voltage Distribution Network in New Zealand. *IET GTD*, 10, 2016, doi:10.1049/iet-gtd.2014.1076
4. Singh R., Tripathi P. and Yatendra K.: Impact of Solar Photovoltaic Penetration In Distribution Network. 2019 3rd International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE), 10, 2019, doi:10.1109/RDCAPE47089.2019.8979014
5. Fernández G., Galan N., Marquina D., Martínez D., Sanchez A., López P., Bludszuweit H., Rueda J.: Photovoltaic Generation Impact Analysis in Low Voltage Distribution Grids. *Energies*. 13 (17), 2020, 4347, doi:10.3390/en13174347
6. Gandhi O., Kumar D.S., Rodríguez-Gallegos C.D., Srinivasan D.: Review of power system impacts at high PV penetration. Part I: Factors limiting PV penetration. *Solar Energy*, 210, 2020, doi:10.1016/j.solener.2020.06.097
7. Korab R., Połomski M., Smółka M.: Evaluating the Risk of Exceeding the Normal Operating Conditions of a Low-Voltage Distribution Network due to Photovoltaic Generation. *Energies* 15, 2022, 1969, doi:10.3390/en15061969
8. Korab R., Połomski M., Smółka M.: Wpływ źródeł PV na pracę sieci nN. *Śląskie Wiadomości Elektrotechniczne*, 5 (137), 2021
9. Upadhyay P., Kern J., Vadlamani V.: Impact of Reverse Power Flow on Transformer, „*CIGRE S&E*”, 19, 2020
10. Hanzelka Z., Piątek K., red. Instalacje fotowoltaiczne w systemie elektroenergetycznym. Wydawnictwo Naukowe PWN, Warszawa 2024

11. Smółka M., Korab R., Połomski M.: Minimalizacja wpływu prosumenckich mikroinstalacji fotowoltaicznych na pracę sieci niskiego napięcia. *Przegląd Elektrotechniczny*, R 100, nr 10, 2024, doi:10.15199/48.2024.10.01
12. Pijarski P., Kacejko P., Adamek S.: Analysis of Voltage Conditions in Low Voltage Networks Highly Saturated with Photovoltaic Micro Installations, *Acta Energetica*, 3, 2018
13. Topolski Ł., Woźny K., Hanzelka Z.: Kompensacja asymetrii prądów i napięć powodowanej odbiornikami i odnawialnymi źródłami energii za pomocą transformatora symetryzującego w sieciach niskich napięć. *Przegląd Elektrotechniczny*, 9 (95), 2019, doi:10.15199/48.2019.09.39
14. Topolski Ł., Schab W., Flirt A., Piątek K.: Analiza wpływu generacji rozproszonej na wybranej parametry jakości energii elektrycznej w sieci niskiego napięcia na terenie klastra Wirtualna Zielona Elektrownia Ochotnica. *Przegląd Elektrotechniczny*, 3 (96), 2020, doi:10.15199/48.2020.03.05
15. Ozorowski M., Jąloza R.: Poprawa parametrów jakościowych sieci zasilającej nn z dużym nasyceniem mikroinstalacji PV i stacji ładowania EVC. *Wiadomości Elektrotechniczne*, 5 (88), 2020
16. Krzemiński Z.: Regulacja napięcia w sieci nN z rozproszonymi źródłami energii. *Przegląd Elektrotechniczny*, 5 (96), 2020, doi:10.15199/48.2020.05.06
17. Mnich T.: Podobciążeniowy układ regulacji w transformatorach rozdzielczych. *Przegląd Elektrotechniczny*, 11 (96), 2020, doi:10.15199/48.2020.11.06
18. U. Zafar, S. Bayhan, A. Sanfilippo, Home Energy Management System Concepts, Configurations, and Technologies for the Smart Grid, *IEEE Access* 8, 2020, doi:10.1109/ACCESS.2020.3005244.
19. B. Han, Y. Zahraoui, M. Mubin, S. Mekhilef, M. Seyedmahmoudian, A. Stojcevski, Home Energy Management Systems: A Review of the Concept, Architecture, and Scheduling Strategies, *IEEE Access* 11, 2023, doi:10.1109/ ACCESS.2023.3248502.
20. Barry J, Böttcher D, Pfeilsticker K, Herman-Czezuch A, Kimiaie N, Meilinger S, et al. Dynamic model of photovoltaic module temperature as a function of atmospheric conditions. In: *Advances in science and research*, vol. 17. Copernicus GmbH; 2020, p. 165–73. doi.org/10.5194/asr-17-165-2020
21. EPRI: OpenDSS PVSystem Element Model. Version 1. February 23, 2011. www.epri.com/pages/sa/opensdss

22. Raport zawierający wstępne wyniki NSP 2021 [GUS] <https://stat.gov.pl/spisy-powszechne/nsp-2021/nsp-2021-wyniki-wstepne/raport-zawierajacy-wstepne-wyniki-nsp-2021,6,1.html>
23. Polska w liczbach 2024 [GUS] <https://stat.gov.pl/obszary-tematyczne/inne-opracowania/inne-opracowania-zbiorcze/polska-w-liczbach-2024,14,17.html>
24. Karta katalogowa panelu LR4-60HPH 350-380M produkcji LONGi Solar Technology Co., Ltd.
25. International Energy Agency, Renewable Energy Market Update. Outlook for 2023 and 2024., iea.blob.core.windows.net/assets/63c14514-6833-4cd8-ac53-f9918c2e4cd9/RenewableEnergyMarketUpdate_June2023.pdf
26. Raport URE, www.ure.gov.pl/pl/urząd/informacje-ogólne/aktualnosci/12551,Raport-URE-w-Polsce-działaj-juz-15-mln-mikroinstalacji-OZE.html
27. S. Hummel, C. Betzold, A. Dentel, Impact of the Weather Forecast Quality on a MPC-driven Heat Pump Heating System, CLIMA 2022 conference (May 2022). doi:10.34641/clima.2022.152.
28. B. Uzum, A. Onen, H. M. Hasanien, S. M. Mueen, Rooftop Solar PV Penetration Impacts on Distribution Network and Further Growth Factors—A Comprehensive Review, *Electronics* 55, 10 (1), 2021, doi:10.3390/electronics10010055.
29. Wacks, K.P (1993). The impact of home automation on power electronics. In: *Applied Power Electronics Conference and Exposition*. pp. 3
30. Nutakki M., Mandava S., Review on optimization techniques and role of Artificial Intelligence in home energy management systems, *Engineering Applications of Artificial Intelligence*, 119, 2023, doi.org/10.1016/j.engappai.2022.105721
31. Maciejowska, K. Assessing the Impact of Renewable Energy Sources on the Electricity Price Level and Variability—A Quantile Regression Approach. *Energy Economics*, 85, 2020, doi.org/10.1016/j.eneco.2019.104532
32. B. Setz, S. Graef, D. Ivanova, A. Tiessen, and M. Aiello, “A Comparison of Open-Source Home Automation Systems,” *IEEE Access*, vol. 9, pp. 167332–167352, 2021, doi: 10.1109/ACCESS.2021.3136025

**ZALACZNIK. ZBIÓR POWIĄZANYCH TEMATYCZNIE
ARTYKUŁÓW NAUKOWYCH STANOWIĄCYCH ROZPRAWĘ
DOKTORSKĄ**

- Z.1. Naczyński T., Korab R.: Możliwości kształtowania bilansu energii elektrycznej odbiorcy indywidualnego wyposażonego w źródło fotowoltaiczne. *Przegląd Elektrotechniczny*, 11 (97), 2021, doi:10.15199/48.2021.11.38
- Z.2. Korab R., Połomski M., Naczyński T., Kandzia T.: A dynamic thermal model for a photovoltaic module under varying atmospheric conditions. *Energy Conversion and Management*, 280, 2023, doi.org/10.1016/j.enconman.2023.116773
- Z.3. Korab R., Naczyński T., Kandzia T.: Short-term forecasting of photovoltaic power generation. *Przegląd Elektrotechniczny*, 9 (99), 2023, doi:10.15199/48.2023.09.06
- Z.4. Naczyński T., Korab R., Połomski M.: Krótkoterminowe prognozowanie bazowego obciążenia odbiorcy komunalno-bytowego z wykorzystaniem danych historycznych. *Przegląd Elektrotechniczny*, 5 (101), 2025, doi: 10.15199/48.2025.05.05
- Z.5. Korab R., Połomski M., Naczyński T.: Optimal scheduling of energy storage and shiftable loads in grid-connected residential building with photovoltaic micro-installation. *Energies*, 17 (21), 2024, doi.org/10.3390/en17215264

Tabela Z.1

Liczbowe podsumowanie dorobku (stan na dzień 28.08.2025 r.)

Nr artykułu	Liczba punktów MNiSW	Impact Factor IF	Liczba cytowań w bazie:	
			WoS	Google Scholar
Z.1	70	0,4	2	0
Z.2	200	10,9	13	22
Z.3	70	0,4	1	4
Z.4	70	0,4	0	0
Z.5	140	3,2	7	8

SPIS SKRÓTÓW STOSOWANYCH W PRACY

AGD	Household appliances	Artykuły gospodarstwa domowego
AsXSn	Low-voltage self-supporting overhead cable	Kabel napowietrzny samonośny niskiego napięcia
CWU	Domestic hot water	Ciepła woda użytkowa
c_h	Energy price in hour "h"	Cena energii w godzinie „h”
CO	Central heating	Centralne ogrzewanie
$\cos\varphi$	Power factor	Współczynnik mocy
csv	Comma-separated values	Wartości oddzielone przecinkami
DSM	Demad Side Management	Zarządzenie popytem
F&F	Manufacturer of the device - F&F Filipowski	Producent urządzenia - F&F Filipowski
FDM	Finite Difference Method	Metoda różnic skończonych
FR	Flame retardant	Ognioodporny
GUS	Central Statistical Office	Główny Urząd Statystyczny
h	Hour	Godzina
HA	Home Assistant	Home Assistant
HEMS	Home Energy Management System	Domowy system zarządzania energią
HMI	Human-machine interface	Interfejs człowiek-maszyna
I	Current	Prąd
IBM	International Business Machines Corporation	Przedsiębiorstwo IBM
IoT	Internet of Things	Internet Rzeczy
kW	Kilowatt	Kilowat
kWh	Kilowatt-hour	Kilowatogodzina
kWh/rok	Energy consumption in kWh per year	Zużycie energii w kWh w ciągu roku
LiFePO4	Lithium-iron-phosphate battery	Akumulator litowo-żelazowo-fosforanowy
MAE	Mean absolute error	Średni błąd bezwzględny
MAPE	Mean absolute percentntage error	Średni bezwzględny błąd procentowy
Max FN	Maximising financial neutrality	Maksymalizacja neutralności finansowej
MID	Measuring Instruments Directive	Dyrektywa w sprawie przyrządów pomiarowych
Min CE	Minimising electricity costs	Minimalizacja kosztów energii elektrycznej
Modbus RTU	Type of serial communication	Typ komunikacji szeregowej
MQTT	Message Queuing Telemetry Transport	Komunikacja Telemetrii Kolejowania Wiadomości
MW	Megawatt	Megawat
MWh	Megawatt-hour	Megawatogodzina
nN	Low voltage	Niskie napięcie
P_{DC}	Power generated by the photovoltaic panel	Moc generowana przez panel fotowoltaiczny
$P_{EX,h}$	Energy exchange with the grid in hour "h"	Wymiana energii z siecią w godzinie „h”
$P_{FIX,h}$	Fixed load for the customer in „h” hour	Stałe obciążenie odbiorcy w godzinie „h”
PLN/kWh	Energy price per 1 kWh expressed in Polish zloty	Cena energii za 1 kWh wyrażona w złotych polskich
P_{n_PV}	Rated output of the photovoltaic panel	Moc znamionowa panelu fotowoltaicznego
$P_{PV,h}$	Photovoltaic generation in in „h” hour	Generacja źródła fotowoltaicznego w godzinie „h”

$P_{\text{RESS},h}$	Energy storage operating point in hour "h"	Punkt pracy magazynu energii w godzinie „h”
$P_{\text{SHIFT},h}$	Variable load for the customer in „h” hour	Zmienne obciążenie odbiorcy w godzinie „h”
PSO	Particle Swarm Optimization	Optymalizacja rojem cząstek
PV	Photovoltaics	Instalacja fotowoltaiczna
RESS	Residential Energy Storage System	Budynkowy system magazynowania energii
RMSE	Root mean square deviation	Błąd średniokwadratowy
RPi	Microcomputer Raspberry Pi	Mikrokomputer Raspberry Pi
RTV	Consumer electronics	Radio i telewizja
SL	Shiftable loads	Odbiorniki sterowane
SN	Medium voltage	Średnie napięcie
S_n	Rated power of the PV inverter	Moc znamionowa falownika PV
SoC	State of Charge	Stan naładowania
STATCOM	Static Synchronous Compensator	Statyczny synchroniczny kompensator
STO	Standard Test Conditions	Standardowe warunki testowe
SVC	Static VAR compensator	Kompensator mocy biernej
TN-C	TN-C grid system	Układ sieci TN-C
TN-S	TN-S grid system	Układ sieci TN-S
TSDB	Time Series Database	Baza danych szeregów czasowych
U_n	Nominal voltage	Napięcie znamionowe
USB	Universal Serial Bus	Uniwersalna magistrala szeregową
V	Voltage	Napięcie
WLZ	Internal power line	Wewnętrzna linia zasilająca
zł	Polish zloty	Polski złoty

Możliwości kształtowania bilansu energii elektrycznej odbiorcy indywidualnego wyposażonego w źródło fotowoltaiczne

Streszczenie. W artykule omówiono wyniki rejestracji profili zapotrzebowania i generacji w budynku mieszkalnym wyposażonym w instancję fotowoltaiczną. Wskazano na rozbieżność tych profili, skutkującą znaczącą wymianą energii elektrycznej z siecią rozdzielczą. Opracowano model symulacyjny rozpatrywanego obiektu, w którym przeanalizowano wpływ sterowania wybranymi odbiornikami na bilans energii analizowanego odbiorcy (prosumenta). Celem rozszerzenia możliwości kształtowania bilansu energii założono wyposażenie układu w akumulatorowy zasobnik energii elektrycznej, działający zgodnie z założonym algorytmem sterowania. Przeprowadzono również analizę opłacalności zakupu różnych typów zasobników energii.

Abstract. The paper discusses the results of recording demand and generation profiles in a residential building equipped with a photovoltaic source. The divergence of these profiles was pointed out. This divergence results in a significant exchange of electricity with the distribution network. A simulation model of the considered object was developed, in which the influence of control of selected receivers on the energy balance of the examined prosumer was analyzed. To extend the possibilities of forming the energy balance, it was assumed that the system will be equipped with battery storage of electric energy with an appropriate control algorithm. An analysis of the profitability of purchase of different types of energy storage devices was also carried out. (Possibilities of forming the electricity balance of an individual customer equipped with a photovoltaic source)

Słowa kluczowe: prosument, źródło fotowoltaiczne, sterowanie odbiornikami, zasobnik energii elektrycznej

Keywords: prosumer, photovoltaic source, control of electricity receivers, electricity storage

Wstęp

Zwiększający się udział odnawialnych źródeł energii (OZE) powoduje zmianę warunków pracy sieci elektroenergetycznej. Przy pewnym poziomie mocy zainstalowanej w OZE, w sieci mogą okresowo pojawiać się negatywne efekty wynikające z działania tych źródeł wytwórczych. Można do nich zaliczyć [1 – 4]:

- zwiększenie zmienności i przekroczenia dopuszczalnych poziomów napięć oraz pogłębienie się niesymetrii,
- wzrost prądu obciążenia, niekiedy powyżej prądu dopuszczalnego długotrwale dla danego elementu sieci,
- wzrost strat sieciowych,
- pojawienie się odwrotnych przepływów mocy, np. z sieci niskiego (nN) do sieci średniego napięcia (SN).

Obserwowany w ostatnim czasie dynamiczny wzrost mocy zainstalowanej w mikroinstalacjach, głównie fotowoltaicznych (PV), przyłączanych do sieci nN, przyczynia się do znaczącej zmiany dobowego bilansu energii podmiotów posiadających takie instalacje (prosumentów). W gospodarstwach domowych wyposażonych w źródła fotowoltaiczne średnio tylko około 30% generowanej energii jest zużywane w chwili jej wyprodukowania [6]. Powoduje to pojawienie się okresów, w których generacja przewyższa zużycie. Nadmiar generowanej energii jest oddawany, przy czym zwykle nie do rzeczywistego (fizycznego) magazynu, ale do magazynu wirtualnego, jakim jest sieć elektroenergetyczna. Przy niewielkim udziale prosumentów w sumarycznym zapotrzebowaniu odbiorców na danym obszarze, wprowadzane nadwyżki energii nie zaburzają pracy sieci. Jednak przy dużej łącznej mocy instalacji fotowoltaicznych okresowo mogą pojawić się wymienione wyżej negatywne zjawiska. To z kolei wymusza podejmowanie przez operatorów systemów dystrybucyjnych (OSD) odpowiednich działań dostosowawczych, których celem jest zapewnienie prawidłowej pracy sieci bez względu na poziom generacji źródeł PV. Do działań tych należą ograniczenie możliwości przyłączania nowych mikroinstalacji fotowoltaicznych (wymaga zmian prawa) lub rozbudowa sieci [5].

Ograniczanie możliwości przyłączania nowych mikroinstalacji PV, z punktu widzenia OSD, jest działaniem bezkosztowym, jednak jego negatywną konsekwencją jest blokowanie rozwoju tego sektora OZE na niektórych obszarach. Z kolei głębokie działania modernizacyjne i rozwojowe


prowadzone w sieci umożliwiłyby dalszy swobodny rozwój segmentu prosumenckich mikroinstalacji fotowoltaicznych, ale wymagałyby ponoszenia bardzo wysokich nakładów inwestycyjnych, przenoszonych następnie w taryfie dystrybucyjnej na wszystkich odbiorców, za pomocą znacząco zwiększonych stawek opłaty przesyłowej [7]. W związku z tym należy poszukiwać nowych rozwiązań, które będą pozbawione wskazanych wad. Rozwiązaniem, które pozwoli na przyłączanie większej liczby mikroinstalacji fotowoltaicznych, bez jednoczesnej konieczności głębokiej rozbudowy sieci, jest zwiększenie poboru energii w miejscu jej wytworzenia, w tym samym czasie, w którym to wytwarzanie następuje. Można to uzyskać przez odpowiednie sterowanie wybranymi odbiornikami oraz dzięki wykorzystaniu zasobnika energii elektrycznej, przyłączonego w układzie zasilania prosumenta.

W artykule w pierwszej kolejności omówiono zastosowane sposoby rejestracji danych opisujących zapotrzebowanie oraz generację źródła fotowoltaicznego zainstalowanego w analizowanym budynku mieszkalnym. Wybrane wyniki zobrazowano na rysunkach. W kolejnej części przedstawiono model symulacyjny rozpatrywanego obiektu, w którym przeprowadzono badania nad sposobami zwiększenia możliwości autokonsumpcji generowanej energii. Przeanalizowano wpływ przesuwania obciążeń szczytowych oraz magazynowania energii elektrycznej. Na zakończenie porównano opłacalność zakupu różnego typu magazynów energii przeznaczonych do współpracy z instalacją fotowoltaiczną.

Rejestracja profili zapotrzebowania i generacji PV

Rejestracja profili zapotrzebowania i generacji analizowanego prosumenta miała na celu określenie stopnia wykorzystania produkowanej energii w okresach jej wytwarzania, a także identyfikację możliwości zwiększenia poziomu autokonsumpcji za pomocą sterowania wybranymi odbiornikami. Równolegle przeprowadzono szereg pomiarów zużycia energii elektrycznej w obiekcie oraz generacji w zintegrowanym z nim źródle PV. W badaniach wykorzystano rejestrator parametrów sieci wraz z urządzeniami pomocniczymi oraz mikrokomputerem, który zapisywał otrzymane wyniki. Na rys. 1 przedstawiono uproszczony schemat układu pomiarowego, wykorzystanego do rejestracji zapotrzebo-

wania. Z kolei rejestracja generacji źródła PV przeprowadzona została za pomocą aplikacji Fronius Solar.web. W przestrzeni udostępnionej przez producenta zapisane zostały dane dotyczące generacji źródła fotowoltaicznego przesłane z falownika. Dane, które były gromadzone w chmurze zostały pobrane w formie pliku csv.




Rys. 1. Schemat układu pomiarowego wykorzystanego do rejestracji zapotrzebowania w analizowanym budynku jednorodzinnym

Przedstawiony na rys. 2 profil zapotrzebowania obrazuje rzeczywiste zapotrzebowanie na moc w analizowanym budynku w ciągu wybranej doby (dobowe zużycie energii na przedstawionym wykresie wynosi 6,65 kWh). Wyróżnić można zapotrzebowanie podstawowe (5,05 kWh) oraz zapotrzebowanie szczytowe (1,60 kWh), które spowodowane jest załączeniem odbiorników o dużej mocy. Urządzeniami, które odpowiadają za zwiększone zapotrzebowanie są: pralka, zmywarka, czajnik elektryczny oraz płyta indukcyjna. Niektóre z tych odbiorników mogą być wykorzystane do sterowania zapotrzebowaniem analizowanego obiektu.


Na rys. 2 przedstawiono również generację źródła fotowoltaicznego zintegrowanego z instalacją odbiorczą rozpatrywanego budynku. Wygenerowana w analizowanej dobie ilość energii wyniosła 31,34 kWh. Zauważalna jest znacząca rozbieżność zarejestrowanych profili, co powoduje dużą wymianę energii z siecią elektroenergetyczną nN (rys. 3). Wymiana ta była równa 30,89 kWh, z czego 27,79 kWh

stanowiło oddanie do sieci, a 3,10 kWh pobór energii z sieci. Na pokrycie zapotrzebowania budynku wykorzystano jedynie 3,55 kWh generowanej energii, co oznacza, że współczynnik autokonsumpcji w ciągu rozpatrywanej doby wyniósł jedynie

11,34% ($3,55 \text{ kWh} / 31,34 \text{ kWh}$). Powodem tego jest bardzo wysoka generacja źródła PV, przy niewielkim zapotrzebowaniu odbiorcy występującym podczas pracy tego źródła.




Rys. 2. Zarejestrowane dobowe profile zapotrzebowania i generacji źródła PV w analizowanym budynku jednorodzinnym



Rys. 3. Wymiana energii z siecią elektroenergetyczną nN w ciągu rozpatrywanej doby

Model symulacyjny rozpatrywanego obiektu

W celu przeprowadzenia badań dotyczących możliwości zwiększenia stopnia wykorzystania energii produkowanej przez źródło PV w badanym budynku, przy zastosowaniu graficznego środowiska programistycznego LabVIEW [8], zaprojektowano model symulacyjny obiektu, przedstawiony na rys. 4.



Rys. 4. Model symulacyjny rozpatrywanego budynku jednorodzinnego z mikroinstalacją PV i zasobnikiem energii w programie LabVIEW

Danymi wejściowymi do modelu były zarejestrowane dobowe profile mocy generowanej przez źródło PV, profile zapotrzebowania podstawowego budynku oraz profile wybranych odbiorników dużej mocy, których chwila załączenia może być regulowany przez użytkownika. Do tej grupy urządzeń zaliczono pralkę, zmywarkę, czajnik elektryczny oraz płytę indukcyjną. W symulatorze zaimplementowano również zasobnik energii elektrycznej w postaci akumulatora, w którym gromadzona jest nadwyżka produkowanej energii. Danymi wejściowymi dla akumulatora są: pojemność magazynu, minimalny i maksymalny poziom naładowania zasobnika, początkowy stan naładowania, maksymalna moc ładowania i rozładowania oraz sprawność procesów ładowania i rozładowania.


W modelu symulacyjnym w pierwszej kolejności ustalono godziny załączania odbiorników sterowalnych tak, aby ich praca odbywała się wtedy, kiedy moc generowana przez źródło PV przewyższa moc odbieraną. Podczas symulacji model bilansuje moc generowaną przez źródło PV z sumarycznym zapotrzebowaniem odbiorników, z uwzględnieniem wymiany z siecią. W wariantach z zaimplementowanym akumulatorem, w pierwszej kolejności nadmiar mocy generowanej jest wykorzystywany do ładowania zasobnika, a gdy stan naładowania osiągnie wartość maksymalną, wtedy nadmiar produkowanej energii jest oddawany do sieci. W przypadku niedoboru generacji ze źródła PV, w pierwszej kolejności do pokrycia zapotrzebowania jest wykorzystana energia zgromadzona w akumulatorze. W tak zaprojektowanym modelu symulacyjnym przeprowadzono wielowariantowe symulacje pracy analizowanego obiektu. Rozpatrywano możliwość instalacji różnych magazynów energii, co pozwoliło na wybór rozwiązania minimalizującego wymianę z siecią.

Możliwości zwiększenia autokonsumpcji energii

Celem określenia możliwości zwiększenia autokonsumpcji energii produkowanej przez mikroinstalację fotowoltaiczną wykonano dwuetapową symulację obejmującą:

1. sterowanie wybranymi odbiornikami (pralka, zmywarka, czajnik elektryczny, płyta indukcyjna),
2. sterowanie odbiornikami (według programu jak w punkcie 1) oraz akumulatorowym zasobnikiem energii.


Analizy zostały wykonane przy założeniu, że praca źródła PV odbywa się według grafiku pokazanego na rys. 2.



Rys. 5. Profil generacji źródła PV oraz profil zapotrzebowania budynku po zastosowaniu sterowania pracą wybranych odbiorników


Na rys. 5, na tle profilu generacji, przedstawiono profil zapotrzebowania budynku po zastosowaniu sterowania czasem załączania wybranych odbiorników. Z wygenerowanych 31,34 kWh energii na pokrycie zapotrzebowania budynku zużyte zostało 4,75 kWh (3,55 kWh bez sterowania odbiornikami), co oznacza, że współczynnik autokonsumpcji był równy 15,16% (wzrost z poziomu 11,34%).

Aдекватnej zmianie uległa również wymiana energii z siecią (rys. 6), która wyniosła 28,49 kWh (30,89 kWh w wariancie bez sterowania odbiornikami). Zmniejszenie wymiany z siecią wynika z jednakowego zmniejszenia ilości energii oddanej do sieci (spadek z 27,79 kWh do 26,59 kWh) i energii pobranej z sieci (spadek z 3,10 kWh do 1,90 kWh).




Rys. 6. Wymiana energii z siecią elektroenergetyczną nN po zastosowaniu sterowania pracą wybranych odbiorników

W celu dalszego zwiększenia stopnia wykorzystania generowanej energii zamodelowano zasobnik AXIstorage Li 9S (pojemność 8,5 kWh, minimalny stan naładowania 1,7 kWh, maksymalna moc ładowania 6,5 kW, maksymalna moc rozładowania 8,3 kW, sprawność 85%). Ładowanie zasobnika następuje wtedy, gdy moc generowana przewyższa zapotrzebowanie i jest kontynuowane do osiągnięcia pojemności znamionowej. Rozładowanie następuje w sytuacji odwrotnej i kończy się po uzyskaniu minimalnego stanu naładowania. Pracę zasobnika w ciągu analizowanej doby ilustruje rys. 7.



Rys. 7. Praca akumulatorowego zasobnika energii



Rys. 8. Wymiana energii z siecią elektroenergetyczną nN po zastosowaniu magazynowania energii

Praca zasobnika według grafiku pokazanego na rys. 2 pozwoliła na zmagazynowanie 6,80 kWh energii (stan początkowy naładowania zasobnika był równy poziomowi minimalnemu wynoszącemu 1,70 kWh). Uwzględniając zużycie energii przez odbiorniki podczas pracy źródła PV (4,75 kWh), współczynnik autokonsumpcji wzrósł do po-

mu 36,85%. Znaczącej zmianie uległa również wymiana z siecią (rys. 8), która zmniejszyła się do poziomu 19,34 kWh (energia oddana była równa 18,59 kWh, a pobrana 0,75 kWh).

Analiza opłacalności zakupu magazynu energii

Jednostkowa cena magazynu energii zależy m.in. od wykorzystanej technologii. Z uwagi na dużą gęstość energii magazyny przeznaczone do współpracy ze źródłami fotowoltaicznymi zbudowane są najczęściej z akumulatorów litowo-jonowych [9]. Ważnym aspektem jest też żywotność zasobnika, którą można oszacować na podstawie maksymalnej liczby cykli pracy (założono 300 cykli na rok). W tabeli 1 zestawiono najważniejsze dane charakteryzujące rozpatrywane magazyny energii [10, 11] (przyjęto kurs 4,55 zł/euro).

Szacując opłacalność wyposażenia instalacji fotowoltaicznej w zasobnik energii należy uwzględnić stosowany obecnie w Polsce system rozliczeń za energię wprowadzoną i odebraną z sieci przez prosumenta [12]. Zgodnie z tym systemem, dla instalacji o mocy do 10 kW, za 1 kWh energii oddanej do sieci prosument może bez dodatkowych opłat odebrać 0,8 kWh, przy czym rozliczenie jest realizowane w okresach rocznych. Oznacza to, że sieć elektroenergetyczna jest traktowana jako wirtualny magazyn o sprawności 80%.

Przy takim sposobie rozliczeń wartość utraconych 20% energii wprowadzonej do sieci może być traktowana jako strata poniesiona przez prosumenta. Jej ograniczenie jest możliwe przy zastosowaniu zasobnika pozwalającego na zmniejszenie wymiany z siecią (magazynem minimalizującym wymianę z siecią okazał się Tesla Powerwall 2, który posiada największą pojemność magazynową). Zatem za-

kup zasobnika będzie opłacalny ekonomicznie tylko wtedy, kiedy zmniejszenie straty ponoszonej przez prosumenta będzie wyższe niż koszt związany z instalacją magazynu.

W pracy [13], dla analizowanego prosumenta, wykonano symulacje pozwalające na oszacowanie rocznego bilansu energii. Obliczenia pokazały, że przy braku magazynu ilość energii wprowadzana do sieci będzie równa 1926 kWh, czyli utracone zostanie 385 kWh. Przyjmując, że suma ceny energii i stawek opłat zmiennych dla odbiorcy rozliczanego według taryfy G11 wynosi 0,62 zł/kWh [14], maksymalna, możliwa do uzyskania, wartość rocznego zmniejszenia straty prosumenta jest równa 239 zł. Wartość tę należy porównać z rocznym kosztem związanym z instalacją magazynu (tabela 1), oszacowanym jako iloraz ceny zakupu urządzenia i przewidywanej żywotności. Wykonana analiza wskazuje na brak opłacalności zakupu zasobnika energii.

Wnioski

Znacząca rozbieżność profilu produkcji źródła fotowoltaicznego i profilu zapotrzebowania odbiorcy komunalno-bytowego w wielu sytuacjach powoduje dużą wymianę energii z siecią. Ograniczenie tego zjawiska jest możliwe poprzez pewne działania możliwe do wykonania u odbiorcy. Należy do nich zmiana profilu zapotrzebowania przez zastosowanie sterowania czasem załączania wybranych odbiorników oraz zastosowanie magazynowania energii w miejscu jej wytworzenia. Praktyczne wdrożenie wymienionych metod na szerszą skalę wymaga jednak opracowania odpowiednich rozwiązań technicznych i organizacyjnych. Rozwiązania te mogłyby być wzorowane na usłudze *Demand Side Response*, funkcjonującej obecnie na poziomie systemowym.

Tabela 1. Najważniejsze dane rozpatrywanych akumulatorowych zasobników energii oraz wyniki analizy opłacalności zakupu magazynu


Lp.	Typ magazynu	Pojemność	Przewidywana żywotność		Cena zakupu		Roczny koszt instalacji magazynu	Możliwe roczne zmniejszenie straty
		kWh	cykle	lata	zł	zł/kWh	zł	zł
1	Pb 150 Ah	7,2	2500	8,3	4086	568	492	239
2	Pb 200 Ah	9,6	2500	8,3	5448	568	656	239
3	LiFePO ₄ 150 Ah	7,2	5000	16,7	28311	3932	1695	239
4	LiFePO ₄ 200 Ah	9,6	5000	16,7	33142	3452	1985	239
5	BMZ ESS 9.0	8,5	5000	16,7	19063	2243	1141	239
6	AXIStorage Li 9S	8,5	7000	23,3	17383	2045	746	239
7	Fronius Battery 9.0	9,0	8000	26,7	33069	3674	1239	239
8	LG Chem REUS 10	9,8	6000	20,0	20148	2056	1007	239
9	BYD Battery-Box L10.5	10,5	5000	16,7	21664	2063	1297	239
10	Tesla Powerwall 2	14,0	3200	10,7	39271	2805	3670	239

Autorzy: mgr. inż. Tomasz Naczyński, Politechnika Śląska – absolwent 2020, E-mail: tomasz0128@interia.pl; dr hab. inż. Roman Korab prof. PŚ; E-mail: roman.korab@polsl.pl; Politechnika Śląska, KEISU, ul. B. Krzywoustego 2, 44-100 Gliwice

LITERATURA

- [1] Watson, J.D., Watson, N.R., Santos-Martin, D., Wood, A.R., Lemon, S. and Miller, A.J.: Impact of Solar Photovoltaics on the Low-Voltage Distribution Network in New Zealand. IET Gener. Transm. Distrib., 2016, 10, doi.org/10.1049/iet-gtd.2014.1076
- [2] Singh R., Tripathi P. and Yatendra K.: Impact of Solar Photovoltaic Penetration In Distribution Network. 2019 3rd International Conference on Recent Developments in Control, Automation & Power Engineering (RDCAPE), Noida, India, 2019, doi.org/10.1109/RDCAPE47089.2019.8979014.
- [3] Fernández G., Galan N., Marquina D., Martínez D., Sanchez A., López P., Bludszuweit H., Rueda J.: Photovoltaic Generation Impact Analysis in Low Voltage Distribution Grids. Energies. 2020, 13 (17), 4347, doi.org/10.3390/en13174347
- [4] Gandhi O., Kumar D.S., Rodríguez-Gallegos C.D., Srinivasan D.: Review of power system impacts at high PV penetration. Part I: Factors limiting PV penetration. Solar Energy, 2020, 210, doi.org/10.1016/j.solener.2020.06.097

- [5] PTPiREE: Mikroinstalacje w Polsce. www.ptpiree.pl/energetyka-w-polsce/energetyka-w-liczbach/mikroinstalacje-w-polsce (dostęp 2021.04.13)
- [6] Wójcicki R.: Autokonsumpcja energii elektrycznej w prosumenckiej osłonie kontrolnej. Rynek Energii, 2020, 1
- [7] Topolski J.: Potrzebne zmiany regulacji w związku z rozwojem mikroinstalacji OZE. www.cire.pl (dostęp 2021.04.13)
- [8] Chruściel M.: LabVIEW w praktyce. Wydawnictwo BTC, Legonowo 2008
- [9] Wojciechowski H.: Technologie magazynowania energii, cz. I, Instal 2/2017
- [10] Akumulatory ogólnego zastosowania, www.batimex.pl (dostęp 2021.04.16)
- [11] Magazyny energii dla instalacji fotowoltaicznych, www.europe-solarstore.com (dostęp 2021.04.16)
- [12] Ustawa z dnia 20 lutego 2015 r. o odnawialnych źródłach energii. Tekst jednolity. Dz. U. 2020, poz. 261
- [13] Naczyński T.: Źródło fotowoltaiczne w układzie zasilania odbiorcy indywidualnego, Praca dyplomowa magisterska, Politechnika Śląska 2020
- [14] Taryfa dla energii elektrycznej – dla odbiorców grup taryfowych G11, G12, G12w, G13, www.tauron.pl (dostęp 2021.04.16)



A dynamic thermal model for a photovoltaic module under varying atmospheric conditions

Roman Korab^{a,b,*}, Marcin Połomski^{a,c}, Tomasz Naczyński^{a,d}, Tomasz Kandzia^{a,e}

^a Silesian University of Technology, Gliwice, Poland

^b Department of Power Systems and Control, Faculty of Electrical Engineering, Silesian University of Technology, Gliwice, Poland

^c Department of Algorithmics and Software, Faculty of Automatic Control, Electronics and Computer Science, Silesian University of Technology, Gliwice, Poland

^d Joint Doctoral School, Silesian University of Technology, Gliwice, Poland

^e Graduate of Faculty of Electrical Engineering, Silesian University of Technology, Gliwice, Poland

ARTICLE INFO

Keywords:

Photovoltaic module
Temperature prediction
Dynamic thermal model
Finite difference method
Particle swarm optimization

ABSTRACT

Operating temperature strongly affects the performance of the photovoltaic module. Thus, the accurate estimation of the module temperature plays an important role in the assessment of photovoltaic system generation. In this article, it was shown that the existing empirical models are characterized by a limited accuracy in determining the module temperature under varying atmospheric conditions, and the estimation error exceeded 25 °C. This feature of empirical models results from the neglect of the thermal inertia of the module. To solve this problem, a dynamic thermal model for the photovoltaic module was proposed. The proposed model is based on the Finite Difference Method and only uses data on the ambient temperature, solar irradiation, and wind speed. The model coefficients were optimized using the Particle Swarm Optimization method. Developed model was benchmarked against field measurements at the Silesian University of Technology, Poland. The performance of the proposed model was also compared with the performance of the dynamic thermal model proposed by Barry et al., using measurements from systems located in the Allgäu region, Germany. The results demonstrated the effectiveness of the proposed dynamic thermal model for the correct calculation of the photovoltaic module temperature under varying weather conditions. The temperature estimation error did not exceed 9 °C.

1. Introduction

Solar energy can be easily transformed into electricity using photovoltaic (PV) modules. Crystalline silicon modules are widely used and will continue to be the leader of the PV market for some time [1]. The amount of power generated by a PV module depends on several factors including [2]: environmental factors (external), PV system factors (internal), PV system installation factors (operational), PV system cost factors (economic) and other miscellaneous factors. The authors of this review article [2] indicated that approximately 50% of the more than 100 articles reviewed focused on the discussion of the impact of environmental factors on PV function. On this basis, it can be concluded that environmental factors have the greatest impact on the operation of PV systems. The most important environmental factors are [2]: solar irradiance, module temperature, dust accumulation, soiling, and the effect of shading. The authors of other works also analyze the influence of wind on the operation of PV modules [3], and indicate the combined effect of various environmental factors on panel degradation [4], as well as on the natural cleaning process of its surface [5].

Solar irradiance can be defined as the quantity of power coming from the Sun per unit area. The output of a PV module significantly depends on solar irradiance. As solar irradiance increases, the open circuit voltage increases logarithmically, whereas the short circuit current increases linearly [6]. As a result, the electrical power of the PV module also increases [7]. Irradiance usually fluctuates and depends on geographical location, season of the year, the sun's position in the sky, and weather. Clouds are the main cause of the greatest variability of solar irradiance throughout the day. Some of the sunlight can also be blocked by dust. The intensity of dust accumulation depends on environmental factors such as wind speed, humidity, rainfall, the source of dust, particle type, PV module technology, and PV module surface cover [5]. Dust accumulation can cause soiling of the PV module, leading to its partial shading. Trees and buildings may also cast shadow on the PV modules. The effect of shading affects the current flow in the entire module as the cells are normally connected in series.

In addition to solar irradiance, the temperature of the PV module also has a direct influence on power output. The temperature effect

* Correspondence to: Silesian University of Technology, Akademicka 2A44-100, Gliwice, Poland
E-mail address: roman.korab@polsl.pl (R. Korab).

Nomenclature**Symbols**

χ	Constriction factor
Δt	Length of the time interval [s]
ΔT_o	Increase of top oil temperature [$^{\circ}\text{C}$]
ΔT_{or}	Increase of top oil temperature in steady state at rated load [$^{\circ}\text{C}$]
ΔT_{PV}	Increase of PV module temperature [$^{\circ}\text{C}$]
η_{PV}	PV module nominal efficiency
$\max \Delta T $	Maximal temperature difference [$^{\circ}\text{C}$]
$\tau\alpha$	Product of transmissivity and absorbance coefficients
τ_o	Oil thermal time constant [s]
τ_{PV}	PV module thermal time constant [s]
$ \Delta T_{max} $	Difference of maximal temperatures [$^{\circ}\text{C}$]
C	Normalization factor
G_T	Global solar irradiance [W/m^2]
G_T^{NOCT}	Global solar irradiance at NOCT [W/m^2]
K	Load factor
k_{11}	Thermal model constant
N	Number of time intervals before the considered time interval
n	Total number of time intervals in analyzed period
p	Number of general forms of formulas determining the increase of PV module temperature
q	Number of objective functions adopted for the optimization of finite difference thermal models coefficients
R	Ratio of load losses at rated current to no-load losses
T_a	Ambient temperature [$^{\circ}\text{C}$]
T_a^{NOCT}	Ambient temperature at NOCT [$^{\circ}\text{C}$]
T_o	Top oil temperature [$^{\circ}\text{C}$]
T_{PVc}	Calculated PV module temperature [$^{\circ}\text{C}$]
T_{PVm}	Measured PV module temperature [$^{\circ}\text{C}$]
T_{PV}	PV module temperature [$^{\circ}\text{C}$]
T_{PV}^{NOCT}	PV module temperature at NOCT [$^{\circ}\text{C}$]
T_{sky}	Sky temperature [$^{\circ}\text{C}$]
u_1, u_2, u_3	Empirical coefficients
V_w	Wind speed [m/s]
x_1, x_2, x_3, x_4	Empirical coefficients
y	Oil exponent

Acronyms

FDM	Finite Difference Method
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
NOCT	Nominal Operating Cell Temperature
NTC	Negative Temperature Coefficient
PSO	Particle Swarm Optimization
PV	Photovoltaic
RMSE	Root Mean Square Error
SCADA	Supervisory Control And Data Acquisition

with temperature. Simultaneously the short circuit current increases slightly with an increase in the PV module temperature. As a result, the output power drops [8]. The manufacturers provide the value of the power temperature coefficient for PV modules in the technical datasheets. The typical value of this factor ranges from 0.3 to 0.5%/ $^{\circ}\text{C}$ [9] and for the average silicon crystalline PV module this is about 0.4%/ $^{\circ}\text{C}$. This means that a 10 $^{\circ}\text{C}$ increase in temperature results in a 4% reduction in generated power. The temperature of the solar module is usually not measured directly. Instead, it is calculated using appropriate mathematical models. As is shown later in the article, some empirical models can give errors above 25 $^{\circ}\text{C}$. This translates into a 10% error in determining the generated power. For this reason, an accurate calculation of the PV module temperature is essential to obtain the correct prediction of the energy produced. The main goal of this article is to develop a mathematical model that allows the correct calculation of the temperature of a PV module operating under varying atmospheric conditions. Research was started with a literature review. On this basis some empirical models were selected for further analysis.

2. Thermal models for photovoltaic modules – a literature review

The influence of temperature on performance of PV modules has attracted attention over the last few decades. In the literature, different models have been suggested for predicting PV module temperature (T_{PV}). Models for T_{PV} estimation can generally be classified by two approaches: dynamic (transient) and steady state [10].

In the dynamic approach, parameters affecting the changing of the module temperatures are considered to be time dependent [10]. Therefore, these models can accurately predict the value of T_{PV} , particularly when atmospheric conditions vary rapidly, which implies that the PV module experiences thermal transients [11]. Dynamic models are based on the energy balance between the PV module and the surrounding environment and account for weather variables, the thermal capacity of the PV module, the heat transfer processes (convection and radiation), and the conversion into electrical power [12]. Dynamic thermal models can be solved using a first-order difference equation, finite difference, or frequency-domain methods [11]. These models are complex and require relatively long computational time, cost, and effort [13]. For these reasons, much simpler steady-state thermal models for T_{PV} estimation are often used.

In the steady-state approach all parameters are assumed to be time-independent [10]. The intensity of incoming solar irradiance and other parameters that affect the PV module performance, in a short period of time (normally less than 1 h), are assumed to be constant. Steady-state models are relatively simple, characterized by low computing times; nevertheless, these models are not flexible and can overestimate or underestimate the value of T_{PV} [13]. The steady-state thermal models can be broadly classified into three types [11]: (i) models based on a diode PV cell model and T_{PV} to establish the I - V curves, and thus the output power, (ii) models based on the energy balance equation for steady-state conditions, for which the thermal capacity of the PV module and the transient phenomena are neglected, (iii) models applied as a function of incident solar irradiance, ambient temperature, and sometimes wind speed, when considering a PV module as a unique element.

In recent years, considerable effort has been devoted by the scientific community to the development and improvement of approaches for calculating T_{PV} from measurable parameters [13]. In such a process, steady state models from the third group mentioned above have become most common. These models are usually empirical models that express the correlation between temperature of a PV module and relevant meteorological variables. Some correlations include material and system-dependent properties, parameters depending on the type of assembly arrangements/schemes and express the adverse effect of an increasing T_{PV} on module efficiency.

is the result of a connatural characteristic of crystalline silicon cell-based PV modules. The main effect of an increase in PV module temperature is on the open circuit voltage, which decreases linearly

Table 1
Empirical models for estimation of PV module temperature.

No.	Author(s)	Year	Ref.	Empirical model
1	Ross	1976	[14]	$T_{PV} = T_a + 0.03G_T$
2	Rauschenbach	1980	[15]	$T_{PV} = T_a + \frac{G_T}{G_T^{NOCT}} (T_{PV}^{NOCT} - T_a^{NOCT}) \left(1 - \frac{\eta_{PV}}{\tau\alpha}\right)$
3	Risser & Fuentes	1984	[16]	$T_{PV} = 1.31T_a + 0.0282G_T - 1.65V_w + 3.81$
4	Schott	1985	[17]	$T_{PV} = T_a + 0.028G_T - 1$
5	Ross & Smokler	1986	[18]	$T_{PV} = T_a + \frac{G_T}{G_T^{NOCT}} (T_{PV}^{NOCT} - T_a^{NOCT})$
6	Lasnier & Ang	1990	[19]	$T_{PV} = 1.14 (T_a - 25) + 0.0175 (G_T - 300) + 30.006$
7	King	1996	[20]	$T_{PV} = T_a + \frac{G_T}{1000} (0.0712V_w^2 - 2.411V_w + 32.96)$
8	King et al.	1998	[21]	$T_{PV} = T_a + \frac{G_T}{1000} (19.6e^{-0.223V_w} + 11.6)$
9	Tamizhmani et al.	2003	[22]	$T_{PV} = 0.943T_a + 0.028G_T - 1.528V_w + 4.3$
10	King et al. (A)	2004	[23]	$T_{PV} = T_a + G_T e^{-3.56 - 0.0750V_w}$
11	King et al. (B)	2004	[23]	$T_{PV} = T_a + G_T e^{-3.47 - 0.0594V_w}$
12	Duffie & Beckman	2006	[24]	$T_{PV} = T_a + \left(\frac{9.5}{5.7+3.8V_w}\right) \frac{G_T}{G_T^{NOCT}} (T_{PV}^{NOCT} - T_a^{NOCT}) \left(1 - \frac{\eta_{PV}}{\tau\alpha}\right)$
13	Mondol et al.	2007	[25]	$T_{PV} = T_a + 0.031G_T$
14	Skoplaki et al. (A)	2008	[26]	$T_{PV} = T_a + \frac{0.25}{5.7+3.8V_w} G_T$
15	Skoplaki et al. (B)	2008	[26]	$T_{PV} = T_a + \frac{0.32}{8.91+2.0V_w} G_T$
16	Muzathik	2014	[27]	$T_{PV} = 0.943T_a + 0.0195G_T - 1.528V_w + 0.3529$
17	Kamuyu et al.	2018	[28]	$T_{PV} = 0.9458T_a + 0.0215G_T - 1.2376V_w + 2.0458$

T_{PV} – temperature of the PV module, in °C, T_a – ambient temperature, in °C, G_T – solar irradiance, in W/m², V_w – wind speed, in m/s, T_{PV}^{NOCT} – PV module operating temperature at NOCT (nominal operating cell temperature) conditions, in °C, T_a^{NOCT} – ambient temperature at NOCT conditions, 20 °C, G_T^{NOCT} – solar irradiance at NOCT conditions, 800 W/m², η_{PV} – PV module nominal efficiency, $\tau\alpha$ – product of transmissivity and absorbance coefficients, $\eta_{PV} \approx 0.9$.

In this article, empirical models expressing the correlation between the PV module temperature and the ambient temperature, solar irradiance, and wind speed, as commonly measured and forecasted meteorological variables, were only analyzed. Some analyzed correlations are also supplemented with parameters available in the technical datasheets. The examined empirical models are presented in Table 1.

The models listed in Table 1 were developed in the years from 1976 to 2018. Also in recent years, several empirical models were presented. In [29] a model considered the ambient temperature, solar irradiance, and wind speed, as well as the thermal resistances of the PV panel was proposed. An interesting approach was presented in the article [30], in which, using a genetic algorithm, a functions that express the correlations between the PV panel temperature and the ambient temperature, solar irradiance, wind speed, and air humidity were determined. Another model based on correlations, that considers the temperature of the sky and the temperature of the ground, was proposed in [31], and then evaluated and compared with other models in [32]. The latest empirical model was proposed in [33]. In this study, using the meteorological data of Kütahya (Turkey), expressions giving the ambient temperature, solar irradiation, and wind speed were created. Using these expressions, the correlation that gives the temperature of photovoltaic panel cell was developed. The recently developed models can also be analyzed using the methodology presented in this study.

The common feature of the empirical models listed in Table 1 is that the thermal inertia of the PV module is neglected. This means that in the event of a change in the weather factor (ambient temperature, solar irradiation, wind speed), there is an abrupt change of the temperature of the PV module calculated by the models. In the following part of this article, the performance of the models listed in Table 1 under varying atmospheric conditions was evaluated. Before that, however, the source of measurements and measurement results for the selected day (Section 3) and the metrics adopted for evaluating the thermal models (Section 4) were described.

3. The source of measurements and measurement results for the selected day

The models for the estimation of PV module temperature listed in Table 1 were evaluated using measurements from the PV installation located on the roof of the building of the Faculty of Automatic Control, Electronics, and Computer Science of the Silesian University of Technology in Gliwice, Poland (latitude 50.287899 N, longitude 18.6770453 E). This PV installation consists of 66 PV modules with a rated power of 265 W (NeMo 60 P), connected to an inverter with a rated power of 17 kVA (SolarEdge SE17K). Part of the PV installation is shown in Fig. 1(a). Adjacent to the PV installation, there is a weather station measuring ambient temperature and wind speed (Fig. 1(b)). The weather station is also equipped with an external temperature sensor for PV temperature measurement (Fig. 1(c)). The solar irradiance is measured with a pyranometer (Fig. 1(d)).

The weather station (Lufft WS500-UMB) measured ambient temperature with a highly accurate negative temperature coefficient (NTC) resistor (sensor accuracy was ± 0.2 °C for the measurement range -20 °C to 50 °C). The measurement resolution was 0.1 °C, and the sampling rate was 1 min. The wind speed meter used four ultrasonic sensors taking cyclical measurements in all directions (sensor accuracy was ± 0.3 m/s or $\pm 3\%$ for the measurement range 0 to 35 m/s). The measurement resolution was 0.1 m/s, and the sampling rate was 1 s. The average values of wind speed were provided with a resolution of 1 min. The PV module temperature was measured by an NTC external temperature sensor (Remote Temperature Probe WT1) with sensor accuracy of ± 1 °C across the measurement range of -40 °C to 80 °C. The measurement resolution was 0.25 °C, and the sampling rate was 1 min. Global solar irradiance was measured by a thermopile pyranometer (DeltaOHM LPPYRA03 S) mounted on the mast near the weather station. LPPYRA03 S is a class C spectrally flat pyranometer that fully complies with the ISO 9060:2018 standard and meets the requirements defined by the World Meteorological Organization. The measurement range was 0 to 2000 W/m² and the measurement resolution was 1 W/m². The sampling rate was 10 s and the average values of solar irradiance were provided with 1 min resolution.



Fig. 1. The PV installation (a), weather station (b), external temperature sensor for PV temperature measurement (c), and pyranometer (d) on the roof of the building of the Faculty of Automatic Control, Electronics, and Computer Science of the Silesian University of Technology in Gliwice, Poland.

The PV installation was equipped with a Supervisory Control And Data Acquisition (SCADA) system that recorded the described measurements (and also information about the generated power) with a 1 min resolution. Recorded data can be downloaded with 1 min or hourly resolution. The hourly values are the average of the minute values in any given hour. Fig. 2 shows an example of measurements in 1 min resolution on May 24, 2020. Fig. 3 shows data for this day in hourly resolution. This day was selected for evaluating the empirical models listed in Table 1 due to the very changeable weather conditions, in particular the level of solar irradiance, which resulted in high temperature variability of the PV module.

4. Adopted metrics for evaluating the thermal models

To assess the accuracy of the empirical models listed in Table 1, the calculated values of temperature $T_{PVc}(t)$ were compared with the measured values $T_{PVm}(t)$. The quality of individual models were evaluated in five categories, applying the following metrics:

- mean absolute error, in °C:

$$MAE = \frac{1}{n} \sum_{t=1}^n |T_{PVm}(t) - T_{PVc}(t)|, \quad (1)$$




Fig. 2. Solar irradiance, ambient temperature, PV module temperature (a), and wind speed (b) recorded in 1 min resolution on May 24, 2020.




Fig. 3. Solar irradiance, ambient temperature, PV module temperature (a), and wind speed (b) in hourly resolution (calculated based on data recorded in 1 min resolution) on May 24, 2020.

- root mean square error, in °C:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (T_{PVm}(t) - T_{PVc}(t))^2}, \quad (2)$$

- mean absolute percentage error, in %:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{T_{PVm}(t) - T_{PVc}(t)}{T_{PVm}(t)} \right| \cdot 100\%, \quad (3)$$

- maximal temperature difference, in °C:

$$\max |\Delta T| = \max_t |T_{PVm}(t) - T_{PVc}(t)|, \quad (4)$$

- difference of maximal temperatures, in °C:

$$|\Delta T_{max}| = \left| \max_t T_{PVm}(t) - \max_t T_{PVc}(t) \right|, \quad (5)$$

where: $T_{PV_m}(t)$ – measured PV module temperature at time interval t , in °C, $T_{PV_c}(t)$ – calculated PV module temperature at time interval t , in °C, n – total number of time intervals in analyzed period. The metrics defined by formulas (1) to (5) were calculated only for the time intervals in which $G_T(t) > 0$.

Based on the values of the metrics defined above, a ranking of the empirical models was created. In the first step, in each category, the appropriate number of points to the individual models was assigned, ranging from 1 to 17. The model with the highest value of the metric in each category (the worst model) received one point, while the model with the lowest value (the best model) received seventeen points. In the next step, the number of points received by individual models in all categories were added. The model with the highest total number of points received the first position in the ranking. The described procedure and the atmospheric conditions shown in Figs. 2 and 3 were used to evaluate the empirical models listed in Table 1. The results were presented in the next section.

5. Evaluation of empirical models for the estimation of photovoltaic module temperature

The performance of the empirical models listed in Table 1 for the atmospheric conditions provided in hourly resolution (see Fig. 3) were analyzed first. For each empirical model, the daily temperature variation was calculated. The results are shown in Fig. 4. On this basis and based on the measured temperature of the PV module (red line in Fig. 4), the values of the metrics defined by the formulas (1) to (5) were calculated. The results are presented in Table 2. When analyzing the results presented in Fig. 4, it can be seen that some models overestimated, and some underestimated the operating temperature of the PV module. The maximum value of the maximal temperature difference ($\max|\Delta T|$) does not exceed 10 °C. The average value of this metric for all analyzed models is approximately 5 °C (see Table 2). There were also models that determined the temperature of the module with very high accuracy. The best model turned out to be model 11 (King et al. (B)), for which the maximal temperature difference was about 1.5 °C.

Fig. 5 and Table 3 show the results of the calculation for the atmospheric conditions provided in 1 min resolution. Very large discrepancies between the temperature calculated by empirical models and the measured temperature can be observed. The maximum value of the maximal temperature difference exceeds 27 °C. The average value for all models analyzed is approximately 21 °C, while the minimal value is 17 °C (see Table 3). The values of the other metrics are significantly greater than those calculated for the atmospheric conditions provided in hourly resolution (see Fig. 6).

The conducted analysis showed that empirical models, based on measurements of the ambient temperature, solar irradiance, and wind speed, can be used to estimate the temperature of a PV module for atmospheric conditions provided in hourly resolution. For input data provided in 1 min resolution, these models give unacceptably large errors. The main reason for this is that these models assume that the temperature changes immediately as the atmospheric conditions change. However, the PV module are heated up and cooled down gradually due to the large time constant [34]. This means that the steady-state empirical models cannot be justified for calculation of the PV module operating temperature under rapidly varying atmospheric conditions, and a more accurate model is necessary to predict the temperature variation.

In the next part of the article, a proposal for a dynamic model was presented. The concept of this model is based on the thermal model of oil-immersed power transformers described in the international standard IEC 60076-7.

6. The international electrotechnical commission thermal model of oil-immersed power transformers

International standard IEC 60076-7 [35] provides a method for calculating the top oil temperature of oil-immersed power transformers operating with an arbitrarily time-varying load factor, in a time-varying ambient temperature. This standard uses a finite difference method (FDM) for solving the heat-transfer differential equations. After converting the differential equations into difference equations, the top oil temperature can be calculated using formulas:

$$T_o(t) = T_o(t-1) + \Delta T_o(t), \quad (6)$$

$$\Delta T_o(t) = \frac{\Delta t}{k_{11}\tau_o} \left[\left(\frac{1 + K(t)^2 R}{1 + R} \right)^y \Delta T_{or} - (T_o(t-1) - T_a(t)) \right], \quad (7)$$

where: $T_o(t)$ – top oil temperature at time interval t , $T_o(t-1)$ – top oil temperature at time interval $(t-1)$, $\Delta T_o(t)$ – the increase of top oil temperature at time interval t , Δt – the assumed length of the time interval, k_{11} – thermal model constant ($k_{11} = 1$ for transformers cooled by natural convection), τ_o – oil thermal time constant, $K(t)$ – load factor (ratio of load current to rated current) at time interval t , R – ratio of load losses at rated current to no-load losses, y – oil exponent, ΔT_{or} – the increase of top oil temperature in steady state at rated load, $T_a(t)$ – ambient temperature at time interval t .

Formula (7) can be written as:

$$\Delta T_o(t) = \frac{\Delta t}{\tau_o} \left[\Delta T_o(K(t)) - (T_o(t-1) - T_a(t)) \right], \quad (8)$$

where $\Delta T_o(K(t))$ is the increase of the top oil temperature in steady state at load $K(t)$. Formulas (6) and (8) were used to develop a dynamic, finite difference thermal model of a PV module.

7. Finite difference thermal model of a photovoltaic module

Empirical models for estimation of PV module temperature presented in Table 1 can be written in general form as:

$$T_{PV}(t) = xT_a(t) + \Delta T_{PV}(G_T(t), V_w(t)), \quad (9)$$

where: $T_{PV}(t)$ – PV module temperature at time interval t , x – thermal model constant, $T_a(t)$ – ambient temperature at time interval t , $G_T(t)$ – solar irradiance at time interval t , $V_w(t)$ – wind speed at time interval t , $\Delta T_{PV}(G(t), V_w(t))$ – increase of PV module temperature in steady state due to specific atmospheric conditions $G_T(t)$ and $V_w(t)$.

The second element of formula (9) was used to build the finite difference thermal model of a PV module. Substituting $\Delta T_o(K(t))$ for $\Delta T_{PV}(G(t), V_w(t))$, $T_o(t-1)$ for $T_{PV}(t-1)$, and τ_o for τ_{PV} in formula (8) gives:

$$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\Delta T_{PV}(G_T(t), V_w(t)) - (T_{PV}(t-1) - T_a(t)) \right], \quad (10)$$

and, analogous to Eq. (6), the temperature of the PV module can be calculated as:

$$T_{PV}(t) = T_{PV}(t-1) + \Delta T_{PV}(t), \quad (11)$$

where: $T_{PV}(t)$ – PV module temperature at time interval t , $T_{PV}(t-1)$ – PV module temperature at time interval $(t-1)$, $\Delta T_{PV}(t)$ – the increase of PV module temperature at time interval t , τ_{PV} – PV module thermal time constant.

Table 4 presents the formulas for determining the increase of a PV module temperature due to specific atmospheric conditions $G_T(t)$ and $V_w(t)$ at time interval t . These formulas result from the empirical models listed in Table 1. In the proposed finite difference thermal model of a PV module the temperature of the PV module at the first time interval ($t = 1$) was calculated using the appropriate empirical model.




Fig. 4. The temperature of a PV module calculated using various empirical models vs. measured temperature—atmospheric conditions provided in hourly resolution, May 24, 2020.

Table 2

Assessment of the accuracy of empirical models for estimation of PV module temperature for atmospheric conditions provided in hourly resolution.

No.	Author(s)	Year	Metrics for evaluating the thermal models					Position in the ranking
			MAE °C	RMSE °C	MAPE %	max $ \Delta T $ °C	$ \Delta T_{max} $ °C	
1	Ross	1976	1.34	2.00	5.52	5.54	5.54	9
2	Rauschenbach	1980	1.09	1.66	4.55	4.78	4.78	7
3	Risser & Fuentes	1984	3.88	4.00	22.05	6.21	6.21	13
4	Schott	1985	0.91	1.15	4.91	3.05	3.05	5
5	Ross & Smokler	1986	2.85	3.88	11.69	9.46	9.46	14
6	Lasnier & Ang	1990	4.27	4.57	21.26	6.51	5.42	14
7	King	1996	0.53	0.64	2.56	1.50	1.50	2
8	King et al.	1998	1.31	1.66	5.50	2.86	2.11	6
9	TamizhMani et al.	2003	0.90	1.01	4.87	1.94	1.48	3
10	King et al. (A)	2004	0.99	1.26	4.32	2.22	1.05	4
11	King et al. (B)	2004	0.53	0.64	2.51	1.48	1.48	1
12	Duffie & Beckman	2006	2.91	3.78	11.68	6.90	6.90	12
13	Mondol et al.	2007	1.63	2.35	6.67	6.29	6.29	10
14	Skoplaki et al. (A)	2008	3.31	4.28	13.32	7.81	7.81	16
15	Skoplaki et al. (B)	2008	1.40	1.79	5.81	3.10	2.61	8
16	Muzathik	2014	6.40	6.79	32.05	9.29	8.82	17
17	Kamuyu et al.	2018	3.27	3.68	15.30	5.54	4.45	11
Minimum			0.53	0.64	2.51	1.48	1.05	
Average			2.21	2.66	10.27	4.97	4.64	
Maximum			6.40	6.79	32.05	9.46	9.46	

8. Evaluation of the proposed finite difference thermal models of a photovoltaic module

The finite difference thermal model of a PV module, defined by the formulas (10) and (11), was used together with the formulas listed in Table 4, to calculate the temperature of PV module for atmospheric conditions provided in 1 min resolution (Fig. 2). It was assumed that the length of the time interval (Δt) resulted from the resolution of the measurements and was equal to 60 s. The PV module thermal time constant (ΔPV) was assumed to be 600 s [36]. The results of the calculations are shown in Fig. 7. The values of the metrics defined by the formulas (1) to (5) are presented in Table 5. When comparing the values of the metrics determined for the finite difference (FDM) thermal models with the values determined for the corresponding empirical models, a significant increase in the accuracy of the PV module temperature estimation using

FDM models can be observed (see Fig. 8). In particular, the maximum value of the maximal temperature difference (max ΔT) decreased from 27 °C to 14 °C. In turn, the average value of this metric decreased from 21 °C to 9 °C, and the minimum value from 17 °C to 5 °C. The obtained accuracy improvement proves the usefulness of the proposed finite difference thermal models for calculating the temperature of a PV module operating under varying atmospheric conditions. In the next section, five general forms of formulas to calculate $\Delta T_{PV}(t)$ were developed and optimization of their coefficients was performed.

9. Optimization of the finite difference thermal models' coefficients by the particle swarm optimization method

Analyzing the equations presented in Table 4, it was concluded that some of them are similar. On this basis, the equations were categorized




Fig. 5. The temperature of a PV module calculated using various empirical models vs. measured temperature—atmospheric conditions provided in 1 min resolution, May 24, 2020.

Table 3

Assessment of the accuracy of empirical models for estimation of PV module temperature for atmospheric conditions provided in 1 min resolution.

No.	Author(s)	Year	Metrics for evaluating the thermal models					Position in the ranking
			MAE °C	RMSE °C	MAPE %	max $ \Delta T $ °C	$ \Delta T_{max} $ °C	
1	Ross	1976	3.18	5.04	12.89	22.01	9.40	12
2	Rauschenbach	1980	3.02	4.77	12.25	20.98	8.28	9
3	Risser & Fuentes	1984	5.05	6.22	26.82	25.55	11.97	17
4	Schott	1985	3.03	4.47	13.13	18.99	6.21	6
5	Ross & Smokler	1986	4.19	6.70	16.91	27.31	15.14	16
6	Lasnier & Ang	1990	4.45	5.46	21.52	19.11	5.85	13
7	King	1996	2.63	4.17	10.90	20.55	7.08	7
8	King et al.	1998	2.42	3.87	9.99	17.42	3.04	2
9	TamizhMani et al.	2003	3.35	4.83	15.40	20.46	6.68	10
10	King et al. (A)	2004	2.39	3.82	9.90	17.07	2.89	1
11	King et al. (B)	2004	2.57	4.09	10.65	19.64	5.95	4
12	Duffie & Beckman	2006	3.17	4.78	12.68	19.01	3.06	5
13	Mondol et al.	2007	3.35	5.32	13.56	23.02	10.49	14
14	Skoplaki et al. (A)	2008	3.43	5.07	13.62	19.24	0.51	8
15	Skoplaki et al. (B)	2008	2.49	3.96	10.28	17.67	4.25	3
16	Muzathik	2014	6.52	7.75	32.27	25.44	6.01	15
17	Kamuyu et al.	2018	3.80	5.28	17.39	21.57	1.77	11
Minimum			2.39	3.82	9.90	17.07	0.51	
Average			3.47	5.03	15.30	20.88	6.39	
Maximum			6.52	7.75	32.27	27.31	15.14	

into five groups and a general mathematical formula for each group was formulated. These general formulas that determine the increase of a PV module temperature at time interval t are presented in Table 6.

Each general formula representing the $\Delta T_{PV}(t)$ component in Eq. (11) of the FDM model contains a set of coefficients denoted by x_1, x_2, x_3, x_4 (x_4 exclusively in II), and τ_{PV} . The aim was to find the optimal values of these coefficients in terms of the accuracy of the FDM model for each general formula I to V. The Particle Swarm Optimization (PSO) method was employed to achieve this. PSO is a stochastic population-based optimization technique proposed in 1995 by Kennedy and Eberhart [37]. It was originally inspired by the social behavior of bird flocks, fish schools and swarm theory in general. The PSO method has proven practical effectiveness in many application areas. Comprehensive reviews of theoretical and experimental works on PSO have recently been published [38,39]. The PSO variant that

was used is based on the PSO algorithm dedicated to continuous search space, including the concept of the constriction factor χ [40]. A more detailed description of the PSO variant employed in this article can be found in [41].

During the computational experiment, several optimizations were performed using the PSO algorithm in which the objective function being minimized was MAE (1), RMSE (2), or MAPE (3). The coefficients τ_{PV}, x_1, x_2, x_3 , and x_4 (x_4 only for formula II) were optimized for a set of measurement data covering a six-month period (from April to September 2021). Computing the objective function value required the calculation of the temperature values using the FDM model with formulas I to V for each data point (the measurement data were in minute resolution) and then the calculation of the value of MAE (1), RMSE (2), or MAPE (3). The population size of the swarm was chosen experimentally and set to 40. The search dimension was equal to the




Fig. 6. Comparison of metrics for evaluating the thermal models calculated for empirical models listed in Table 1 for atmospheric conditions provided in hourly and 1 min resolution, May 24, 2020.

number of coefficients in the given formulas I to V, with decision variables τ_{PV} , x_1 , x_2 , x_3 , and x_4 (x_4 only for formula II). The lower and upper bounds on the decision variables were set to -50 and 50 ,

respectively. The lower and upper bounds on the velocities of particles were set to -10 and 10 , respectively. The constriction factor value was set to $\chi = 0.5$. Two types of stopping criteria were used; the first

Table 4

Formulas determining the increase of the PV module temperature at time interval t resulting from the empirical models given in Table 1.

No.	Author(s)	Finite difference model – the increase of PV module temperature at time interval t
1	Ross	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.03 G_T(t)) - (T_{PV}(t-1) - T_a(t)) \right]$
2	Rauschenbach	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{G_T(t)}{G_T^{NOCT}} (T_{PV}^{NOCT} - T_a^{NOCT}) \right) \left(1 - \frac{\eta_{PV}}{\tau_a} \right) \right] - (T_{PV}(t-1) - T_a(t))$
3	Risser & Fuentes	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.0282 G_T(t) - 1.65 V_{we}(t) + 3.81) - (T_{PV}(t-1) - T_a(t)) \right]$
4	Schott	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.028 G_T(t) - 1) - (T_{PV}(t-1) - T_a(t)) \right]$
5	Ross & Smokler	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{G_T(t)}{G_T^{NOCT}} (T_{PV}^{NOCT} - T_a^{NOCT}) \right) - (T_{PV}(t-1) - T_a(t)) \right]$
6	Lasnier & Ang	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.0175 G_T(t) - 3.744) - (T_{PV}(t-1) - T_a(t)) \right]$
7	King	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{G_T(t)}{1000} (0.0712 V_{we}^2(t) - 2.411 V_{we}(t) + 32.96) \right) - (T_{PV}(t-1) - T_a(t)) \right]$
8	King et al.	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{G_T(t)}{1000} (19.6 e^{-0.223 V_{we}(t)} + 11.6) \right) - (T_{PV}(t-1) - T_a(t)) \right]$
9	TamizhMani et al.	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.028 G_T(t) - 1.528 V_{we}(t) + 4.3) - (T_{PV}(t-1) - T_a(t)) \right]$
10	King et al. (A)	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(G_T(t) e^{-3.56 - 0.0750 V_{we}(t)}) - (T_{PV}(t-1) - T_a(t)) \right]$
11	King et al. (B)	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(G_T(t) e^{-3.47 - 0.0594 V_{we}(t)}) - (T_{PV}(t-1) - T_a(t)) \right]$
12	Duffie & Beckman	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\left(\frac{9.5}{5.7 + 3.8 V_{we}(t)} \right) \left(\frac{G_T(t)}{G_T^{NOCT}} (T_{PV}^{NOCT} - T_a^{NOCT}) \right) \left(1 - \frac{\eta_{PV}}{\tau_a} \right) \right) - (T_{PV}(t-1) - T_a(t)) \right]$
13	Mondol et al.	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.031 G_T(t)) - (T_{PV}(t-1) - T_a(t)) \right]$
14	Skoplaki et al. (A)	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{0.25}{5.7 + 3.8 V_{we}(t)} G_T(t) \right) - (T_{PV}(t-1) - T_a(t)) \right]$
15	Skoplaki et al. (B)	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{0.32}{8.91 + 2.0 V_{we}(t)} G_T(t) \right) - (T_{PV}(t-1) - T_a(t)) \right]$
16	Muzathik	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.0195 G_T(t) - 1.528 V_{we}(t) + 0.3529) - (T_{PV}(t-1) - T_a(t)) \right]$
17	Kamuyu et al.	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(0.0215 G_T(t) - 1.2376 V_{we}(t) + 2.0458) - (T_{PV}(t-1) - T_a(t)) \right]$




Fig. 7. The temperature of a PV module calculated using various finite difference models vs. measured temperature—atmospheric conditions provided in 1 min resolution, May 24, 2020.

Table 5

Assessment of the accuracy of proposed finite difference thermal models of a PV module for atmospheric conditions provided in 1 min resolution.

No.	Author(s)	Year	Metrics for evaluating the thermal models					Position in the ranking
			MAE °C	RMSE °C	MAPE %	max $ \Delta T $ °C	$ \Delta T_{max} $ °C	
1	Ross	1976	1.86	2.58	7.83	8.90	4.25	11
2	Rauschenbach	1980	2.21	2.42	2.02	7.58	4.30	9
3	Risser & Fuentes	1984	0.88	1.22	4.39	5.71	1.28	3
4	Schott	1985	1.22	1.57	6.22	5.83	2.36	5
5	Ross & Smokler	1986	2.89	4.03	12.14	12.35	10.26	14
6	Lasnier & Ang	1990	6.07	6.57	30.54	14.37	10.37	17
7	King	1996	0.84	1.21	4.08	5.39	0.81	1
8	King et al.	1998	1.45	2.04	6.15	8.49	3.39	8
9	Tamizhmani et al.	2003	1.14	1.41	6.59	4.91	2.01	4
10	King et al. (A)	2004	1.24	1.77	5.43	7.67	2.55	6
11	King et al. (B)	2004	0.87	1.24	4.17	5.50	0.53	2
12	Duffie & Beckman	2006	2.80	3.85	11.03	12.56	8.02	13
13	Mondol et al.	2007	1.76	2.56	7.66	9.11	6.22	12
14	Skoplaki et al. (A)	2008	3.22	4.40	12.65	13.49	9.44	15
15	Skoplaki et al. (B)	2008	1.48	2.08	6.21	8.79	3.56	10
16	Muzathik	2014	5.71	6.26	27.84	14.38	9.94	16
17	Kamuyu et al.	2018	1.44	1.60	1.51	10.33	5.35	7
Minimum			0.84	1.21	1.51	4.91	0.53	
Average			2.18	2.76	9.20	9.14	4.98	
Maximum			6.07	6.57	30.54	14.38	10.37	

Table 6

General forms of formulas determining the increase of PV module temperature at time interval t .

No.	Based on model(s) no. (see Table 4)	General form of formula determining the increase of PV module temperature
I	1, 3, 4, 6, 7, 13, 16, 17	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[(x_1 G_T(t) + x_2 V_{w(t)} + x_3) - (T_{PV}(t-1) - T_a(t)) \right]$
II	7	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[x_1 G_T(t) (x_2 V_{w(t)} + x_3 V_{w(t)} + x_4) - (T_{PV}(t-1) - T_a(t)) \right]$
III	10, 11	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[x_1 G_T(t) (e^{x_2 V_{w(t)} + x_3}) - (T_{PV}(t-1) - T_a(t)) \right]$
IV	8	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[x_1 G_T(t) (e^{x_2 V_{w(t)} + x_3}) - (T_{PV}(t-1) - T_a(t)) \right]$
V	2, 5, 12, 14, 15	$\Delta T_{PV}(t) = \frac{\Delta t}{\tau_{PV}} \left[\left(\frac{x_1 G_T(t)}{x_2 V_{w(t)} + x_3} \right) - (T_{PV}(t-1) - T_a(t)) \right]$

Table 7

Results of optimization of finite difference thermal models' coefficients by the PSO method.

No.	τ_{PV} sec	x_1	x_2	x_3	x_4	MAE °C	RMSE °C	MAPE °C
MAE minimization								
I	490	0.02374	-0.52803	0.92683	-	1.717	5.484	11.18
II	506	0.01000	0.00009	-0.26811	2.98493	1.444	2.061	9.401
III	516	0.38449	-0.14050	-2.48248	-	1.422	2.034	9.296
IV	519	0.02506	-0.25147	0.34845	-	1.416	2.027	9.251
V	519	-1.51417	-10.14780	-43.53743	-	1.417	2.028	9.249
RMSE minimization								
I	439	0.02333	-0.01473	-0.38287	-	1.801	2.516	10.706
II	474	0.01000	0.00009	-0.26666	2.94147	1.449	2.055	9.375
III	483	0.43827	-0.14559	-2.62086	-	1.427	2.026	9.273
IV	487	0.02524	-0.24912	0.32470	-	1.420	2.021	9.229
V	488	-0.11078	-0.76956	-3.20710	-	1.420	2.022	9.225
MAPE minimization								
I	457	0.02149	-0.07893	0.10528	-	1.821	2.645	10.410
II	509	0.01000	0.00008	-0.23334	2.80773	1.469	2.076	9.324
III	520	1.77116	-0.13191	-4.06584	-	1.442	2.042	9.233
IV	527	0.02258	-0.32136	0.48214	-	1.437	2.038	9.186
V	525	-0.29929	-2.03390	-9.01629	-	1.435	2.036	9.190

was the maximum number of iterations (predefined to 300), and the second was the maximum number of iterations in which the objective function result did not improve (predefined to 70). Table 7 shows the optimization results of the coefficients of the formulas I to V using the PSO method. To obtain the optimal values of the decision variables (presented in Table 7) for a given variant of the general FDM model and a given objective function, 20 optimization tasks were performed. The average value of the results obtained was taken as a final result.

10. Evaluation of finite difference thermal models with optimized coefficients

The temperature of PV modules calculated using FDM models with optimized coefficients is shown in Fig. 9. The values of the metrics defined by the formulas (1) to (5) are presented in Table 8. Comparing the obtained results with the results obtained using the models listed in Table 4 (the results are presented in Fig. 7 and Table 5), shows that




Fig. 8. Comparison of metrics for evaluating the thermal models calculated for empirical models listed in Table 1 and for proposed finite difference models for atmospheric conditions provided in 1 min resolution, May 24, 2020.

a significant reduction in the dispersion of the obtained temperature courses can be noticed. FDM models with optimized coefficients gave the maximal temperature difference ($\max |\Delta T|$) ranging from 6.57 $^{\circ}C$

to 9.76 $^{\circ}C$ (the dispersion was 3.19 $^{\circ}C$), while for the models listed in Table 4 this range was from 4.91 $^{\circ}C$ to 14.38 $^{\circ}C$ (the dispersion was 9.47 $^{\circ}C$). A similar reduction in dispersion can be observed in




Fig. 9. The temperature of the PV module calculated using finite difference models with optimized coefficients vs. measured temperature—atmospheric conditions provided in 1 min resolution, May 24, 2020.

Table 8

Assessment of the accuracy of finite difference thermal models with optimized coefficients for atmospheric conditions provided in 1 min resolution, May 24, 2020.

No.	Metrics for evaluating the thermal models					Position in the ranking
	MAE °C	RMSE °C	MAPE %	max ΔT °C	$ \Delta T_{max} $ °C	
MAE minimization						
I	1.24	1.72	5.54	6.98	1.23	1
II	1.48	2.04	6.17	8.36	3.27	2
III	1.61	2.22	6.65	8.88	3.63	3
IV	1.70	2.34	6.97	9.18	3.87	4
V	1.70	2.34	6.97	9.15	3.90	5
MAE minimization						
I	1.26	1.73	5.80	6.57	0.77	1
II	1.57	2.15	6.50	8.54	3.38	2
III	1.72	2.36	7.05	9.13	3.80	3
IV	1.79	2.45	7.29	9.35	3.97	4
V	1.79	2.44	7.29	9.33	4.01	5
MAE minimization						
I	1.48	2.06	6.39	7.58	2.41	1
II	1.65	2.26	6.82	8.72	3.89	2
III	1.77	2.43	7.27	9.22	4.26	3
IV	1.94	2.65	7.87	9.76	4.74	5
V	1.88	2.57	7.67	9.57	4.60	4
The minimum, average, and maximum values of the metrics						
Minimum	1.24	1.72	5.54	6.57	0.77	
Average	1.64	2.25	6.82	8.69	3.45	
Maximum	1.94	2.65	7.87	9.76	4.74	

relation to the other metrics defined in Section 4. The average values of all metrics for the FDM models with optimized coefficients decreased noticeably. The obtained improvement in the accuracy of PV module temperature estimation proves the validity of the optimization of the FDM model coefficients.

11. Generalized form of the finite difference thermal model of a photovoltaic module

After optimizing the coefficients, fifteen different FDM models were obtained (five general forms of formulas determining the increase of

Table 9

Assessment of the accuracy of the generalized form of the finite difference thermal model for atmospheric conditions provided in 1 min resolution, May 24, 2020.

MAE °C	RMSE °C	MAPE %	max ΔT °C	$ \Delta T_{max} $ °C
1.62	2.22	6.75	8.69	3.55

PV module temperature at time interval t , each formula optimized for three objective functions). As shown in Fig. 9, each model gives a slightly different estimate of the PV module temperature. Having the temperature measurements, it is possible to select the model that gives the smallest errors. However, in the absence of measurements, the best model cannot be identified. The authors of the article [13] stated that the best strategy to obtain T_{PV} estimation is connecting several temperature sensors and averaging the measurements. Applying a similar strategy, a generalized form of the finite difference thermal model of a PV module was defined as:

$$\bar{T}_{PV}(t) = \frac{1}{pq} \sum_{j=1}^{q=3} T_{PV}(t)_{i,j}, \quad (12)$$

$$T_{PV}(t)_{i,j} = T_{PV}(t-1)_{i,j} + \Delta T_{PV}(t)_{i,j}, \quad (13)$$

where: $\Delta T_{PV}(t)_{i,j}$ – the increase in PV module temperature at time interval t calculated using one of the general form of formulas ($i = 1, \dots, p$) with coefficients optimized for one of the adopted objective functions ($j = 1, \dots, q$), p – the number of general forms of formulas determining the increase of PV module temperature, $p = 5$, (see Table 6), q – the number of objective functions adopted for the optimization of finite difference thermal models' coefficients, $q = 3$, (see Table 7).

The performance of the generalized FDM model for the atmospheric conditions provided in 1 min resolution is shown in Fig. 10. The values of the metrics defined by the formulas (1) to (5) are presented in Table 9.

Comparing the results obtained using the generalized form of the FDM model with the results obtained using empirical models (Fig. 5 and Table 3), a significant improvement in the accuracy of the PV module temperature estimation can be observed. This confirms the usefulness of the proposed approach. In the next part of the article, the




Fig. 10. The temperature of a PV module calculated using the generalized form of finite difference model vs. measured temperature—atmospheric conditions provided in 1 min resolution, May 24, 2020.




Fig. 11. The temperature of the PV module calculated using the generalized form of finite difference model and Barry et al.'s dynamic model vs. measured temperature—atmospheric conditions provided in 1 min resolution, September 14, 2018.

proposed FDM model were compared with another dynamic thermal model proposed by Barry et al. using measurements from PV systems located in the Allgäu region, Germany.

12. Comparison of the generalized finite difference model with another dynamic thermal model of photovoltaic module

To verify the proposed model more deeply, the results obtained using the generalized FDM model were compared with the results obtained using the dynamic model proposed in [36] by Barry et al. In Barry et al.'s model the PV module temperature time series T_{PV} is

written in matrix notation as:

$$\mathbf{T}_{PV} = \mathbf{M}_\tau \left[\mathbf{T}_a + \frac{\mathbf{G}_T}{u_1 + u_2 \mathbf{V}_w} + u_3 (\mathbf{T}_{sky} - \mathbf{T}_a) \right], \quad (14)$$

where u_1 , u_2 , and u_3 are the empirical coefficients, $\mathbf{T}_a$, $\mathbf{G}_T$, $\mathbf{V}_w$, and $\mathbf{T}_{sky}$ are ambient temperature, solar irradiance, wind speed, and sky temperatures time series vectors respectively. The matrix $\mathbf{M}_\tau$ is defined as:

$$\mathbf{M}_{\tau,i,j} = \begin{cases} 0 & \text{for } i - j < 0 \\ \frac{\exp(-(i-j)\Delta t/\tau_{PV})}{C} & \text{for } 0 \leq i - j \leq N \\ 0 & \text{for } i - j > N \end{cases}, \quad (15)$$




Fig. 12. The temperature of the PV module calculated using the generalized form of finite difference model and Barry et al.'s dynamic model vs. measured temperature—atmospheric conditions provided in 1 min resolution, September 27, 2018.




Fig. 13. The temperature of the PV module calculated using the generalized form of finite difference model and Barry et al.'s dynamic model vs. measured temperature—atmospheric conditions provided in 1 min resolution, October 4, 2018.

where C is the normalization factor given by the formula:

$$C = \sum_{j=\max(0, i-N)}^i \exp(-(i-j)\Delta t/\tau_{PV}), \quad (16)$$

and N is the number of time intervals before the considered time interval. In Barry et al.'s model, the PV module temperature at each time interval in the past contributes to the temperature at the considered time interval, with an exponentially decreasing weight.

The performance of the generalized form of the FDM model and the Barry et al.'s model was compared for three selected days with different atmospheric conditions:

1. September 14, 2018 – a day with high variability of solar irradiance,
2. September 27, 2018 – a completely cloudless day,

3. October 4, 2018 – a cloudless day with morning fog.

The atmospheric conditions and the measured temperature of PV modules on selected days are shown in the figures in the appendix. All data are available at [42]. The results of the calculations are shown in Table 10 and Figs. 11, 12, and 13. The results presented indicate that both models accurately reproduced the temperature variation of the PV modules. The proposed FDM model was characterized by a higher accuracy for September 27 and October 4, while for September 14, the Barry et al.'s model turned out to be more precise.

13. Conclusion

The operating temperature of the PV module has a direct influence on power output, but the PV module temperature is usually




Fig. A.1. Solar irradiance, ambient temperature, PV module temperature, sky temperature (a), and wind speed (b) recorded in 1 min resolution on September 14, 2018.




Fig. A.2. Solar irradiance, ambient temperature, PV module temperature, sky temperature (a), and wind speed (b) recorded in 1 min resolution on September 27, 2018.

not measured. Instead, it can be calculated using appropriate mathematical models. Empirical models are often used for this purpose. These models express the correlation between the module temperature and the variables describing atmospheric conditions. In the article, it was shown that empirical models, based on measurements of ambient temperature, solar irradiance, and wind speed, can be used to estimate the temperature of the PV module for atmospheric conditions provided in hourly resolution. In this case, the maximal temperature difference

between the measured values and those calculated by the analyzed empirical models ranged from 1.5 $^{\circ}\text{C}$ to 10 $^{\circ}\text{C}$.

However, for input data for the same day provided in 1 min resolution, the empirical models give unacceptably large errors. The maximal temperature difference between the measured and calculated values ranged from 17 $^{\circ}\text{C}$ to 27 $^{\circ}\text{C}$. For the silicon crystalline PV module with a power temperature coefficient equal to 0.4%/ $^{\circ}\text{C}$, this translates into an error in determining the generated power ranged from 6.8% to 10.8%.




Fig. A.3. Solar irradiance, ambient temperature, PV module temperature, sky temperature (a), and wind speed (b) recorded in 1 min resolution on October 4, 2018.

Table 10

Assessment of the accuracy of generalized form of the finite difference thermal model and Barry's et al. dynamic model for atmospheric conditions provided in 1 min resolution.

Day	Model	MAE °C	RMSE °C	MAPE %	max ΔT °C	$ \Delta T_{max} $ °C
September 14, 2018	Generalized FDM	1.03	1.34	4.34	5.08	2.63
	Barry et. al	0.75	1.13	2.71	4.07	0.32
September 27, 2018	Generalized FDM	1.95	2.43	296.40	5.63	1.79
	Barry et. al	4.15	4.30	300.26	7.26	3.39
October 4, 2018	Generalized FDM	1.25	1.65	8.57	5.08	1.54
	Barry et. al	1.50	1.87	12.39	5.50	1.10

Such significant values of temperature estimation errors result from the neglect of the thermal inertia of the PV module in empirical models. This means that in the event of a change in the weather factors, there is an abrupt change of the temperature of the PV module calculated by the models.

To resolve indicated problem, the finite difference thermal model, which considers the dynamic of temperature changes of PV modules operating under varying atmospheric conditions, was proposed. The effectiveness of the proposed FDM model has been demonstrated by experimental validation with outdoor module temperature measurements under different weather conditions. The temperature estimation error did not exceed 9 °C, which means that the PV panel generation estimation error was less than 3.6%. The obtained results have demonstrated the ability of the FDM model to adequately characterize the thermal behavior of the PV modules, when compared with the prior-art empirical models. This makes the proposed model further beneficial for predicting the output power of PV modules.

CRedit authorship contribution statement

Roman Korab: Conceptualization, Methodology, Data curation, Formal analysis, Investigation, Validation, Visualization, Writing – original draft. **Marcin Połomski:** Software, Investigation, Formal analysis, Validation, Writing – review & editing. **Tomasz Naczyński:** Data curation, Formal analysis, Investigation, Visualization, Writing –

review & editing. **Tomasz Kandzia:** Data curation, Formal analysis, Investigation, Visualization, Writing – review & editing.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Data availability

Data will be made available on request.

Appendix

See Figs. A.1–A.3.

References

- [1] Kumar NM, Chopra SS, de Oliveira AKV, Ahmed H, Vaezi S, et al. Chapter 3 - Solar PV module technologies. In: Gorjian S, Shukla A, editors. Photovoltaic solar energy conversion. Academic Press; 2020, p. 51–78. <http://dx.doi.org/10.1016/B978-0-12-819610-6.00003-X>.
- [2] Fouad MM, Shihata LA, Morgan EI. An integrated review of factors influencing the performance of photovoltaic panels. Renew Sustain Energy Rev 2017;80:1499–511. <http://dx.doi.org/10.1016/j.rser.2017.05.141>.

- [3] Pradhan A, Panda B. Analysis of ten external factors affecting the performance of PV system. In: 2017 international conference on energy, communication, data analytics and soft computing. 2017, p. 3093–8. <http://dx.doi.org/10.1109/ICECDS.2017.8390025>.
- [4] Vidyandandan KV. An overview of factors affecting the performance of solar PV systems. *Energy Scan* 2017;27:2–8.
- [5] Hasan K, Yousuf SB, Tushar MSHK, Das BK, Das P, Islam MS. Effects of different environmental and operational factors on the PV performance: A comprehensive review. *Energy Sci Eng* 2022;10(2):656–75. <http://dx.doi.org/10.1002/ese3.1043>.
- [6] Meral ME, Dincer F. A review of the factors affecting operation and efficiency of photovoltaic based electricity generation systems. *Renew Sustain Energy Rev* 2011;15(5):2176–84. <http://dx.doi.org/10.1016/j.rser.2011.01.010>.
- [7] Salim MS, Najim JM, Salih SM. Practical evaluation of Solar Irradiance Effect on PV performance. *Energy Sci Technol* 2013;6(2):36–40. <http://dx.doi.org/10.3968/j.est.1923847920130602.2671>.
- [8] Skoplaki E, Palyvos JA. On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations. *Sol Energy* 2009;83(5):614–24. <http://dx.doi.org/10.1016/j.solener.2008.10.008>.
- [9] Seme S, Krawczyk A, Łada-Tondyrya E, Štumberger B, Hadžiselimović M. The efficiency of different orientations of photovoltaic systems. *Prz Elektrotech* 2017;1:201–4. <http://dx.doi.org/10.15199/48.2017.01.49>.
- [10] Jakhani AQ, Othman A-K, Rigit ARH, Samo SR. Determination and comparison of different photovoltaic module temperature models for Kuching, Sarawak. In: 2011 IEEE conference on clean energy and technology. 2011, p. 231–6. <http://dx.doi.org/10.1109/CET.2011.6041469>.
- [11] Osma-Pinto G, Ordóñez-Plata G. Dynamic thermal modelling for the prediction of the operating temperature of a PV panel with an integrated cooling system. *Renew Energy* 2020;152:1041–54. <http://dx.doi.org/10.1016/j.renene.2020.01.132>.
- [12] Li C, Spataru SV, Zhang K, Yang Y, Wei H. A multi-state dynamic thermal model for accurate photovoltaic cell temperature estimation. *IEEE J Photovolt* 2020;10(5):1465–73. <http://dx.doi.org/10.1109/JPHOTOV.2020.2987401>.
- [13] Santos LdO, de Carvalho PCM, Filho CdOC. Photovoltaic cell operating temperature models: A review of correlations and parameters. *IEEE J Photovolt* 2022;12(1):179–90. <http://dx.doi.org/10.1109/JPHOTOV.2021.3113156>.
- [14] Ross RG. Interface design considerations for terrestrial solar cells modules. In: Proceedings of the 12th IEEE photovoltaic specialists conference. 1976, p. 801–6.
- [15] Rauschenbach HS. Solar cell array design handbook. New York: Van Nostrand Reinhold Co.; 1980, p. 390–1.
- [16] Risser VV, Fuentes MK. Linear regression analysis of flat-plate photovoltaic system performance data. In: Photovoltaic solar energy conference; Proceedings of the fifth international conference. Athens, Greece: D. Reidel Publishing Co.; 1984, p. 623–7.
- [17] Schott T. Operation temperatures of PV modules: A theoretical and experimental approach. In: Proceedings of the sixth EC photovoltaic solar energy conference. 1985.
- [18] Ross RG, Smokler MI. Electricity from photovoltaic solar cells: Flat-plate solar array project final report. Volume VI: Engineering sciences and reliability. Springfield, VA: JPL Publication, NASA; 1986.
- [19] Lasnier F, Ang TG. Photovoltaic engineering handbook. New York: Adam Hilger; 1990, p. 258.
- [20] King DL. Photovoltaic module and array performance characterization methods for all system operating conditions. *AIP Conf Proc* 1997;394(1):347–68. <http://dx.doi.org/10.1063/1.52852>.
- [21] King D, Kratochvil J, Boyson W, Bower W. Field experience with a new performance characterization procedure for photovoltaic arrays. In: 2nd world conference and exhibition on photovoltaic solar energy conversion. 1998.
- [22] Tamizhmani G, Ji L, Tang Y, Petacci L, Osterwald C. Photovoltaic module thermal/wind performance: Long-term monitoring and model development for energy rating. In: NCPV and solar program review meeting proceedings, NREL/CD-520-33586. 2003, p. 936–8.
- [23] King DL, Boyson WE, Kratochvil JA. Photovoltaic array performance model. SAND2004-3535, Sandia National Laboratories; 2004, p. 18–20.
- [24] Duffie JA, Beckman WA. Solar engineering of thermal processes 3rd edition. Hoboken: Wiley; 2006, p. 759–61.
- [25] Mondol JD, Yohanis YG, Norton B. Comparison of measured and predicted long term performance of grid a connected photovoltaic system. *Energy Convers Manage* 2007;48(4):1065–80. <http://dx.doi.org/10.1016/j.enconman.2006.10.021>.
- [26] Skoplaki E, Boudouvis AG, Palyvos JA. A simple correlation for the operating temperature of photovoltaic modules of arbitrary mounting. *Sol Energy Mater Sol Cells* 2008;92(11):1393–402. <http://dx.doi.org/10.1016/j.solmat.2008.05.016>.
- [27] Muzathik AM. Photovoltaic modules operating temperature estimation using a simple correlation. *Int J Energy Eng* 2014;4(4):151–8.
- [28] Charles Lawrence Kamuyu W, Lim JR, Won CS, Ahn HK. Prediction model of photovoltaic module temperature for power performance of floating PVs. *Energies* 2018;11(2):447. <http://dx.doi.org/10.3390/en11020447>.
- [29] Jacques S. Chapter 5 The importance of cell temperature in modelling the energy efficiency of PV modules. In: Advances in renewable energies and power quality. 2020, Hal-02525736.
- [30] Sohani A, Sayyaadi H. Employing genetic programming to find the best correlation to predict temperature of solar photovoltaic panels. *Energy Convers Manage* 2020;224.
- [31] Aoun N. Outdoor testing of free standing PV module temperature under desert climate: A comparative study. *Int J Ambient Energy* 2021;42(13):1484–91. <http://dx.doi.org/10.1080/01430750.2019.1611640>.
- [32] Aoun N. Methodology for predicting the PV module temperature based on actual and estimated weather data. *Energy Convers Manag* X 2022;14:100182. <http://dx.doi.org/10.1016/j.ecmx.2022.100182>.
- [33] Yolcan OO, Kose R. Photovoltaic module cell temperature estimation: Developing a novel expression. *Sol Energy* 2023;249:1–11. <http://dx.doi.org/10.1016/j.solener.2022.11.020>.
- [34] Armstrong S, Hurley WG. A thermal model for photovoltaic panels under varying atmospheric conditions. *Appl Therm Eng* 2010;30(11):1488–95. <http://dx.doi.org/10.1016/j.applthermaleng.2010.03.012>.
- [35] International Standard IEC 60076-7. Power transformers – Part 7: Loading guide for oil-immersed power transformers. IEC 60076-7:2005.
- [36] Barry J, Böttcher D, Pfeilsticker K, Herman-Czezuch A, Kimiaie N, Meilinger S, et al. Dynamic model of photovoltaic module temperature as a function of atmospheric conditions. In: Advances in science and research, vol. 17. Copernicus GmbH; 2020, p. 165–73. <http://dx.doi.org/10.5194/asr-17-165-2020>.
- [37] Kennedy J, Eberhart R. Particle swarm optimization. In: Proceedings of ICNN'95 - international conference on neural networks, vol. 4. 1995, p. 1942–8. <http://dx.doi.org/10.1109/ICNN.1995.488968>.
- [38] Bonyadi MR, Michalewicz Z. Particle swarm optimization for single objective continuous space problems: A review. *Evol Comput* 2017;25(1):1–54. http://dx.doi.org/10.1162/EVCO_r_00180.
- [39] Shami TM, El-Saleh AA, Alswaiti M, Al-Tashi Q, Summakieh MA, Mirjalili S. Particle swarm optimization: A comprehensive survey. *IEEE Access* 2022;10:10031–61. <http://dx.doi.org/10.1109/ACCESS.2022.3142859>.
- [40] Clerc M, Kennedy J. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *IEEE Trans Evol Comput* 2002;6(1):58–73. <http://dx.doi.org/10.1109/4235.985692>.
- [41] Korab R, Polomski M, Owczarek R. Application of particle swarm optimization for optimal setting of phase shifting transformers to minimize unscheduled active power flows. *Appl Soft Comput* 2021;105:107243. <http://dx.doi.org/10.1016/j.asoc.2021.107243>.
- [42] Barry J, Böttcher D, Pfeilsticker K, Herman-Czezuch A, Kimiaie N, Meilinger S, et al. Supplement to “Dynamic model of photovoltaic module temperature as a function of atmospheric conditions”. Zenodo; 2020, <http://dx.doi.org/10.5281/zenodo.3958820>.

Short-term forecasting of photovoltaic power generation

Abstract. In this article, a method for short-term forecasting of photovoltaic (PV) generation was proposed. The proposed method belongs to the group of physical methods and is based on numerical weather forecasts. The generation forecast was determined using the PV source model in the OpenDSS software. The results of calculations were compared with the results of measurements from the operating PV micro-installations.

Streszczenie. W artykule zaproponowana została metoda krótkoterminowego prognozowania generacji źródła fotowoltaicznego (PV). Metoda ta należy do grupy tzw. metod fizycznych i bazuje na numerycznych prognozach pogody. Do wyznaczenia prognozy generacji zastosowano model źródła fotowoltaicznego wchodzący w skład pakietu OpenDSS. Wyniki prognoz zostały porównane w wynikami pomiarów pochodzących z działających mikroinstalacji PV. (Krótkoterminowe prognozowanie generacji źródła fotowoltaicznego)

Keywords: photovoltaic source, prosumer, generation forecasting, physical method, numerical weather forecast, OpenDSS

Słowa kluczowe: źródło fotowoltaiczne, prosument, prognozowanie generacji, metoda fizyczna, numeryczna prognoza pogody, OpenDSS

Introduction

The increasing power of renewable energy sources [1], especially prosumer photovoltaic (PV) micro-installations [2], changes the operating conditions of the power grid. Distribution system operators are increasingly reporting emerging problems in the operation of the low-voltage (LV) grid. These problems mainly concern an increase in voltage above the permissible limit, the appearance of the reverse power flow from the LV network to the medium-voltage (MV) network, an increase in voltage asymmetry, and a higher load of some network elements. The described phenomena occur locally, in places where a large number of PV micro-installations have been connected [3]. The risk of exceeding the normal operating conditions of the LV network increases as the power of PV sources increases [4].

Excessive power of PV sources connected locally to the LV grid also affects the situation of prosumers, especially during periods of high solar irradiation, when they produce the majority of the energy. Due to the low demand that usually occurs at this time, most of the energy produced is transmitted to the grid. This raises the voltage at the prosumer's connection point. Once the voltage exceeds the permissible limit, the inverter turns off and no energy is produced despite favorable weather conditions. As a result, the prosumer suffers a measurable loss. The situation described is illustrated in Figure 1.




Fig. 1. Phase voltages and power generated by a PV micro-installation belonging to one of the authors of the article (measurements from May 15, 2022; visible interruptions in production caused by switching off the inverter due to exceed the voltage limit)

The standard method to improve the operating conditions of the LV grid with connected PV micro-installations is its modernization. Modernization usually consists in increasing the power of the MV/LV transformer and the cross sec-

tion of the conductors, as well as shortening the LV circuits [5]. However, this is a costly method and takes a long time to implement the investment. An alternative solution is to increase the consumption of energy at the place where it is generated, at the same time as this generation occurs, i.e., to increase self-consumption. This can be achieved by appropriate control of selected household electrical appliances owned by the prosumer and using energy storages, connected in the prosumer's power supply system [6]. Proper determination of the operating schedule of these devices during the day requires a forecast of the generation of the PV source.

Numerous studies have reviewed various PV power forecasting methodologies [7-11]. These works classify PV power forecasting mainly depending on the forecasting horizon and methods used to forecast. The duration of time for which the forecasting of the PV power output is performed is called the forecasting horizon [8, 10]. Based on the time horizon, forecasting of PV power generation can be generally divided into three categories: long-term (done from one month to several years), medium-term (done for more than one week to one month), and short-term (done for one hour, several hours, one day or up to seven days). Long-term forecasts are used to plan the development of electricity generation, transmission, and distribution. Medium-term forecasts are important for planning the maintenance of power plants and networks in a cost-effective way. Short-term forecasts of PV generation are useful in unit commitment and dispatching of electrical power, as well as in scheduling of spinning reserves and demand response. These types of forecasts are also helpful in designing a PV integrated energy management system for buildings.

There are two main methods used for forecasting PV generation, namely statistical and physical [7, 9, 11]. Statistical approach consists in predicting the power output using historical data. Therefore, the quality of the data is essential for an accurate forecast. Statistical methods require a large historical dataset (meteorological and power measurements) to correctly define the correlation among them. The selection of a suitable training dataset becomes crucial for the accuracy. The statistical approach includes artificial neural networks, support vector machines, Markov chain, autoregressive, and regression models. Statistical models do not need any technical information from the PV system to model them. In contrast, the second approach, i.e., physical methods (also known as PV performance models), uses analytical equations and technical data to model the PV system. These methods use forecasted meteorological data

to calculate PV production. The main advantage of physical methods over the statistical methods is that no historical data are needed. However, the major disadvantage of these models is the high dependence on weather forecast, especially the forecast of solar irradiance. Physical methods include numerical weather forecasts, sky imagery, and satellite-imaging models.

In this article, we propose a physical method for short-term forecasting of a PV generation, based on numerical weather forecasts. We determine the generation forecast using the PV source model in the OpenDSS software. We compare the results of the calculations with the results of measurements from the operating PV micro-installations.

Model of a PV source

The PV source model used by OpenDSS [12] is presented in Figure 2 [4]. To parameterize the model, we first define the rated power of the PV panels $P_{r,PV}$ under standard test conditions. The power generated by the PV panels is determined for a given level of solar irradiance and is dependent upon the panel temperature, so the obtained power value must be corrected accordingly. The temperature of the PV panels is calculated using an external model based on ambient temperature, solar irradiance intensity, and wind speed. The DC power generated P_{DC} is then converted according to the efficiency characteristic of the inverter, for which the rated power S_r , the rated voltage U_r , and the power factor pf are given. The active power P and the reactive power Q generated by the PV source are calculated at the output of the inverter.




Fig. 2. The PV source model used by OpenDSS [4]

In the following part of the article, the PV source model will be validated using the measurements for the PV installation operating at the Silesian University of Technology.

The PV micro-installation at the Silesian University of Technology (SUT)

The SUT PV micro-installation is located on the roof of the building of the Faculty of Automatic Control, Electronics and Computer Science (Fig. 3). This building is equipped with three PV installations. Installation no. 3 was selected for the tests, because in the other two there was periodic shading of the PV panels by building elements. The selected installation is characterized by the same angle of inclination and orientation of all panels towards the cardinal directions. The installation consists of 66 NeMo 60 P modules with a rated power of 265 W, which gives a total installed power of 17.49 kW. It is based on the SolarEdge system, consisting of 33 power optimizers (P600) and an inverter (SE17K) with a rated power of 17 kVA.



Fig. 3. PV installation on the roof of the building of the Faculty of Automatic Control, Electronics, and Computer Science of the Silesian University of Technology in Gliwice, Poland

Adjacent to the PV installation, there is a weather station measuring ambient temperature and wind speed. The weather station is also equipped with an external temperature sensor for PV temperature measurement. The solar irradiance is measured with a pyranometer. The PV installation is equipped with a SCADA (Supervisory Control And Data Acquisition) system that records the weather conditions and generated power with an one-minute resolution.

Weather conditions during the selected days

Two random days from 2021 were selected for the analysis. These days differed primarily in the intensity of solar irradiation. The first day, June 27, was a sunny day with temporary clouds. The second day, September 29, was cloudy with varying degrees of cloud cover. The weather conditions on selected days are illustrated in Figures 4 and 5. These figures also show the recorded temperature variability of the PV panels.




Fig. 4. Solar irradiance, ambient temperature, PV module temperature (a), and wind speed (b) on June 27, 2021




Fig. 5. Solar irradiance, ambient temperature, PV module temperature (a), and wind speed (b) on September 29, 2021

Correction of solar irradiance

Figures 4a and 5a show the measured intensity of solar irradiation falling on a horizontal surface. On this basis, the intensity of solar irradiation incident on the surface of PV modules, that are inclined to the horizontal at an angle of 12° and tilted from the north-south axis by 35° in the eastern direction, was determined. The calculations used a procedure according to PN-EN ISO 52010-1:2017-09, as described in the article [13]. Parameters that define the position of the sun relative to the PV panels were determined using the NOAA Solar Calculator [14]. Figures 6 and 7 compare the measured and corrected solar irradiance. The corrected solar irradiance will be used to calculate the generation of PV panels.




Fig. 6. Solar irradiance on sloped surface (corrected) vs. solar irradiance on a horizontal surface (measured) on June 27, 2021




Fig. 7. Solar irradiance on sloped surface (corrected) vs. solar irradiance on a horizontal surface (measured) on September 29, 2021

Estimation of the PV module temperature

The operating temperature of the PV panel has a direct influence on power output. As the temperature increases, power generation decreases. The power temperature coefficient for PV panels in considered micro-installation was equal to 0.42%/°C. This means that a 10°C increase in temperature results in a 4.2% reduction in generated power. In the article, a dynamic thermal model proposed in [15] was used to determine the temperature of PV panels. This model is based on the finite difference method and uses data on ambient temperature, solar irradiation, and wind speed. The measured and calculated daily variation of PV panels temperature is shown in Figures 8 and 9. The temperature estimation error did not exceed 9°C on June 27 and 5°C on September 29.




Fig. 8. Temperature of a PV module calculated using the finite difference model vs. measured temperature – atmospheric conditions on June 27, 2021




Fig. 9. Temperature of a PV module calculated using the finite difference model vs. measured temperature – atmospheric conditions on September 29, 2021

Validation of the PV source model

The PV source model was parameterized according to the technical data for the analyzed SUT PV micro-installation. Subsequently, corrected solar irradiance (Figures 6 and 7) and calculated PV panel temperature (Figures 8 and 9) were entered into the model. On this basis, the generation of the micro-installation was calculated for the two days analyzed. The results of the calculation were compared with the generation measured on those days. The results are presented in Figures 10 and 11.




Fig. 10. Generation of PV installation calculated using the PV source model vs. measured power – atmospheric conditions on June 27, 2021




Fig. 11. Generation of PV installation calculated using the PV source model vs. measured power – atmospheric conditions on September 29, 2021

Comparing the results obtained using the PV source model with the measurements (Figs. 10 and 11), a high accuracy of estimation of the PV generation can be observed. The quality of PV model can be evaluated applying the mean absolute percentage error (MAPE) defined as:

$$(1) \quad MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{P_m(t) - P_c(t)}{P_m(t)} \right| \cdot 100\%$$

where: $P_m(t)$ – measured PV generation at time interval t , in kW, $P_c(t)$ – calculated PV generation at time interval t , in kW, n – the total number of time intervals in analyzed period (1440). The values of MAPE errors for both days analyzed, as well as the measured and calculated amount of a daily energy production, are given in Table 1.

Table 1. Daily energy production and MAPE

Day	Daily energy production			MAPE
	Measured	Calculated	Difference	
	kWh	kWh	%	%
June 27	98.6	105.9	7.4	18.6
September 29	38.5	39.8	3.4	8.7

The applied model of the PV source turned out to be less accurate for a day with a higher level of solar irradiance. An in-depth analysis of the results allowed us to conclude that the largest difference between the measured and calculated PV generation occurs for the morning hours (up to 6.00) and the afternoon hours (after 16.00). If only hours from 6.00 to 16.00 are considered for the assessment of the model accuracy (approximately 90% of the daily energy is generated during this period), the error values are significantly smaller (see Table 2).

Table 2. Energy production and MAPE – hours from 6.00 to 16.00

Day	Daily energy production			MAPE
	Measured kWh	Calculated kWh	Difference %	
June 27	87.3	91.8	5.2	6.8
September 29	36.9	37.8	2.3	4.9

The described model can also be used to determine the forecasted generation of the PV source. For this purpose, numerical weather forecasts should be used as input to the model.




Fig. 12. Numerical weather forecast from the platform A for June 27, 2021 (hourly resolution)




Fig. 13. Numerical weather forecast from the platform B for June 27, 2021 (hourly resolution)




Fig. 14. Numerical weather forecast from the platform B for June 27, 2021 (5 minute resolution)




Fig. 15. Numerical weather forecast from the platform A for September 29, 2021 (hourly resolution)




Fig. 16. Numerical weather forecast from the platform B for September 29, 2021 (hourly resolution)




Fig. 17. Numerical weather forecast from the platform B for September 29, 2021 (5 minute resolution)

Numerical weather forecasts

The numerical weather forecasts used in the calculations came from two internet platforms (A and B). Both platforms provide information about the forecasted ambient temperature, wind speed, and solar irradiation through the API (application programming interface). The geographic resolution for platform A is 4 km and for platform B is 2 km. Platform A allows to download data in hourly resolution, while platform B in hourly and five-minute resolution. The weather forecasts from both platforms for the two days analyzed in the article are shown in Figures 12-17.

PV generation forecasts

Using the procedure described in the previous sections, and based on the numerical weather forecasts presented in Figures 12-17, appropriate forecasts of the generation of the PV source with an installed capacity of 17.49 kW were determined. The calculation results are shown in Figures 18-23 and Table 3.




Fig. 18. Forecast of PV generation based on the platform A weather forecast (1 h) vs. measured power on June 27, 2021




Fig. 19. Forecast of PV generation based on the platform B weather forecast (1 h) vs. measured power on June 27, 2021




Fig. 20. Forecast of PV generation based on the platform B weather forecast (5 min) vs. measured power on June 27, 2021




Fig. 21. Forecast of PV generation based on the platform A weather forecast (1 h) vs. measured power on September 29, 2021




Fig. 22. Forecast of PV generation based on the platform B weather forecast (1 h) vs. measured power on September 29, 2021




Fig. 23. Forecast of PV generation based on the platform B weather forecast (5 min) vs. measured power on September 29, 2021

Table 3. Forecast of daily energy production and MAPE

Day	Platform, resolution	Daily energy production			MAPE
		Measured kWh	Calculated kWh	Difference %	
June 27	A, 1 h	98.6	124.5	26.3	87.1
	B, 1 h		118.3	20.1	59.7
	B, 5 min		114.2	15.9	53.4
September 29	A, 1 h	38.5	72.0	86.9	124.7
	B, 1 h		40.3	4.6	28.5
	B, 5 min		39.9	3.6	26.5

The obtained generation forecasts differ from the actual production of the analyzed PV source. The accuracy of the forecasts is different for both the days considered and for different numerical weather forecasts. The forecasts obtained for the numerical weather forecasts from platform A are characterized by the lowest accuracy. The highest accuracy was obtained for platform B weather forecasts with a five-minute resolution. In the best case, the difference between the forecast and the actual generation was 3.6%, and the MAPE error did not exceed 27%.

In the following section, weather forecasts in five-minute resolution from platform B will be used to forecast the generation of prosumer micro-installations.

Generation forecast for a prosumer PV installations

The developed method was used to calculate the generation forecast for two prosumer micro-installations. The first is located in Koszęcin (Silesian Voivodeship). It is a household PV installation with an installed power of 7.32 kW. The installation consists of 24 IBC Solar PV panels with a power of 305 W and a Fronius Symo 6.0-3M inverter with a rated power of 6 kW. In the analyzed installation, the panels face south-west and are inclined at an angle of 35°. The forecast was developed using the numerical weather forecast for June 10, 2022 (Fig. 24). The results are shown in Figure 25 and Table 4.




Fig. 24. Numerical weather forecast from the platform B for June 10, 2022 (5 minute resolution)




Fig. 25. Forecast of PV generation based on the platform B weather forecast (5 min) vs. measured power on June 10, 2022

Table 4. Daily energy production and MAPE

Day	Daily energy production			MAPE
	Measured kWh	Calculated kWh	Difference %	
June 10	28.4	26.5	-6.8	43.1

The second micro-installation is located in Łącza (Silesian Voivodeship). The installation consists of 20 LONGI Solar LR6-60PE modules with a rated power of 305 W, which gives a total power of 6.1 kW. The panels are connected to the Fronius Symo 5.0-3M inverter with a rated power of 5 kW. In the analyzed installation, the panels face south and are inclined at an angle of 15°. The forecast was prepared for June 16, 2022, also using the numerical weather forecast from platform B in a five-minute resolution (Fig. 26). The calculation results are shown in Figure 27 and Table 5.




Fig. 26. Numerical weather forecast from the platform B for June 16, 2022 (5 minute resolution)




Fig. 27. Forecast of PV generation based on the platform B weather forecast (5 min) vs. measured power on June 10, 2022

Table 5. Daily energy production and MAPE

Day	Daily energy production			MAPE
	Measured	Calculated	Difference	
	kWh	kWh	%	%
June 16	23.9	30.8	28.7	70.0

Conclusions

The article presents a method of forecasting the generation of a PV source using numerical weather forecasts including the forecast of solar irradiation, ambient temperature, and wind speed. The possibility of using hourly and five-minute weather forecasts from two meteorological platforms was analyzed. The results of the forecasts were compared with the actual generation of three operating PV micro-installations.

The accuracy of PV generation forecasts depends on the source of the numerical weather forecasts and their resolution, as well as on the nature of the weather on the analyzed day, in particular on the nature of cloud cover. In the article, days with highly variable cloudiness were selected for analysis. From the point of view of forecasting the generation of a PV source, these are days for which forecasting is very difficult. The analyzes performed indicate that much higher accuracy was obtained for weather forecasts with a five-minute resolution. This type of PV source generation forecast is characterized by sufficient accuracy

to be used to determine the operating schedule of the selected household electrical appliances and energy storages owned by prosumers in order to increase the self-consumption of the produced energy.

Autorzy: dr hab. inż. Roman Korab prof. PŚ; E-mail: roman.korab@polsl.pl, Politechnika Śląska, Katedra Elektroenergetyki i Sterowania Układów, ul. B. Krzywoustego 2, 44-100 Gliwice; mgr inż. Tomasz Kandzia, Politechnika Śląska, Wydział Elektryczny, absolwent 2022, E-mail: tomaszkandzia@protonmail.com; mgr inż. Tomasz Naczyński – Politechnika Śląska, Wspólna Szkoła Doktorów, doktorant; E-mail: tomasz.naczynski@polsl.pl;

LITERATURA

- [1] pse.pl/dane-systemowe/funkcjonowanie-kse/raporty-roczone-z-funkcjonowania-kse-za-rok/raporty-za-rok-2021 (in Polish)
- [2] ptpiree.pl/energetyka-w-polsce/energetyka-w-liczbach/mikroinstalacje-w-polsce (in Polish)
- [3] Topolski Ł., Schab W., Flirt A., Piątek K.: Analysis of the impact of dispersed generation on selected aspects of power quality in a low-voltage electricity network located in the area of energy cluster Virtual Green Ochotnica Power Plant. *Przegląd Elektrotechniczny*, vol. 3 (96), 2020, doi: 10.15199/48.2020.03.05 (in Polish)
- [4] Korab R., Polomski M., Smółka M.: Evaluating the Risk of Exceeding the Normal Operating Conditions of a Low-Voltage Distribution Network due to Photovoltaic Generation. *Energies* 2022, 15, 1969, doi:10.3390/en15061969
- [5] Adamek S.: Methods to reduce adverse impact of prosumer microinstallations on LV distribution systems. *Rynek Energii*, vol. 6 (163), 2022 (in Polish)
- [6] Naczyński T., Korab R.: Possibilities of forming the electricity balance of an individual customer equipped with a photovoltaic source. *Przegląd Elektrotechniczny*, vol. 11 (97), 2021, doi:10.15199/48.2021.11.38 (in Polish)
- [7] Antonanzas J., Osorio N., Escobar R., Urraca R., Martinez-de-Pison F.J., Antonanzas-Torres F.: Review of photovoltaic power forecasting. *Solar Energy*, vol. 136, 2016, doi:10.1016/j.solener.2016.06.069
- [8] Das U.K., Tey K.S., Seyedmahmoudian M., Mekhilef S., Idris M.Y.I., Van Deventer W., Horan B., Stojcevski A.: Forecasting of photovoltaic power generation and model optimization: A review, *Renewable and Sustainable Energy Reviews*, vol. 81, part 1, 2018, doi:10.1016/j.rser.2017.08.017
- [9] Sobri S., Koohi-Kamali S., Rahim N.A.: Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, vol. 156, 2018, doi:10.1016/j.enconman.2017.11.019
- [10] Akhter M.N., Mekhilef S., Mokhlis H., Shah N.M.: Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. *IET Renewable Power Generation*, 2019, 13, doi:10.1049/iet-rpg.2018.5649
- [11] Wu Y.K., Huang C.L., Phan Q.T., Li Y.Y.: Completed Review of Various Solar Power Forecasting Techniques Considering Different Viewpoints. *Energies* 2022, 15, 3320, doi:10.3390/en15093320
- [12] EPRI: OpenDSS PVSystem Element Model. Version 1. February 23, 2011. www.epri.com/pages/sa/opensds
- [13] Michalak P.: Modelling of solar irradiance incident on building envelopes in Polish climatic conditions: the impact on energy performance indicators of residential buildings. *Energies* 2021, 14, 4371. <https://doi.org/10.3390/en14144371>
- [14] NOAA Solar Calculator, gml.noaa.gov/grad/solcalc/index.html
- [15] Korab R., Polomski M., Naczyński T., Kandzia T.: A dynamic thermal model for a photovoltaic module under varying atmospheric conditions. *Energy Conversion and Management*, vol. 280, 2023, doi.org/10.1016/j.enconman.2023.116773

Krótkoterminowe prognozowanie bazowego obciążenia odbiorcy komunalno-bytowego z wykorzystaniem danych historycznych

Short-term forecasting of the baseline load of the residential customer using historical data

Streszczenie. W artykule omówiono metodę prognozowania dobowego przebiegu obciążenia odbiorcy komunalno-bytowego. Opisana metoda bazuje na założeniach metody naiwnej i wykorzystuje historyczne dane dotyczące zużycia energii elektrycznej przez analizowanego odbiorcę. Zaproponowany model prognostyczny może zostać zastosowany do wyznaczenia prognozy obciążenia bazowego, wykorzystywanej przez system zarządzania energią w budynku wyposażonym w źródło fotowoltaiczne, magazyn energii i sterowane odbiorniki.

Abstract. This paper discusses a method for forecasting the daily load profile of a residential consumer. The method described is based on the assumptions of the persistence (naive) method and uses historical data on the electricity consumption by the analyzed customer. The proposed forecasting model can be applied to determine the consumer's baseline load forecast, used by the energy management system in a building equipped with a photovoltaic source, energy storage and shiftable (controllable) loads.

Słowa kluczowe: odbiorca komunalno-bytowy, obciążenie bazowe, krótkoterminowe prognozowanie obciążenia, metoda naiwna
Keywords: residential load, baseline load, short-term load forecasting, persistence (naive) method

Wprowadzenie

Prosumenckie źródła fotowoltaiczne (PV), wraz z domowymi magazynami energii oraz odbiornikami o elastycznym czasie załączania, umożliwiając budowę lokalnych (budynkowych) systemów bilansowania zapotrzebowania odbiorców komunalno-bytowych. Funkcję tę realizują układy określane jako Home Energy Management System (HEMS) [1]. Do prawidłowego zaplanowania pracy poszczególnych urządzeń, oprócz prognozy generacji źródła PV [2], konieczne jest dysponowanie prognozą bazowego obciążenia odbiorcy. Uwzględniając te prognozy, system HEMS określa moce oraz okresy ładowania i rozładowania magazynu, a także momenty włączenia odbiorników o znanych profilach poboru energii i sterowanym czasie załączania [3].

Horyzont czasowy prognozy obciążenia może być różny. Pierwszym rodzajem prognoz są prognozy długoterminowe [4], obejmujące zwykle okres od roku do kilkudziesięciu lat. Tego typu prognozy są wykorzystywane w procesie strategicznego planowania rozwoju systemu elektroenergetycznego. Drugim rodzajem prognoz są prognozy średnioterminowe [5], przygotowywane na okres od tygodnia do roku. Znajdują one zastosowanie m.in. przy planowaniu zabiegów eksploatacyjnych. Kolejną grupę prognoz stanowią prognozy krótkoterminowe [6], przygotowywane najczęściej w rozdzielczości godzinowej dla okresu od kilku do kilkudziesięciu godzin. Właśnie tego typu prognozy są wykorzystywane do planowania operacyjnego w kolejnej dobie. Niekiedy wyróżnia się jeszcze prognozy o krótszym horyzoncie czasowym i wyższej rozdzielczości (ultrakrótkoterminowe) [7], stosowane w bieżącym bilansowaniu zapotrzebowania.

Kolejnym czynnikiem różnicującym rodzaje prognoz jest poziom agregacji, dla którego są one opracowywane [8]. Można tutaj wyróżnić prognozy systemowe, sporządzane dla całego systemu połączonego (np. europejskiego) lub poszczególnych systemów krajowych, prognozy regionalne, wykonywane dla obszarów działania pojedynczych operatorów systemów dystrybucyjnych, prognozy grupowe dla odbiorców o podobnym charakterze zużycia oraz prognozy indywidualne, opracowywane dla pojedynczych odbiorców.

Z punktu widzenia tematyki niniejszego artykułu przedmiotem zainteresowania są indywidualne prognozy krótkoterminowe (dobowe w rozdzielczości godzinowej), sporządzane dla odbiorców komunalno-bytowych.

Prawidłowe prognozowanie obciążenia odbiorcy komunalno-bytowego jest trudnym zadaniem ze względu na znaczną zmienność tego obciążenia. Do typowych czynników mających istotny wpływ na zapotrzebowanie odbiorcy komunalno-bytowego należą: tryb życia i nawyki mieszkańców [9], w tym różne wydarzenia medialne [10], pory roku determinujące m.in. dostępność światła dziennego [11] oraz warunki pogodowe, wpływające na komfort cieplny w budynku [12]. Oprócz tego wpływ na zużycie energii przez gospodarstwa domowe mogą mieć różnego typu programy promujące oszczędność energii [13], a także wzrastająca świadomość ekologiczna społeczeństwa [14]. Obecnie pojawiają się również dodatkowe czynniki wpływające na zapotrzebowanie tej grupy odbiorców. Można do nich zaliczyć m.in. rozwój infrastruktury umożliwiającej zautomatyzowane zarządzanie energią w budynkach [15], dynamiczne ceny energii [16] lub zalecane przez operatorów okresy, w których należy zwiększyć lub zmniejszyć zużycie energii elektrycznej [17].

W literaturze przedmiotu można znaleźć propozycje metod krótkoterminowego prognozowania obciążenia odbiorców komunalno-bytowych, w których uwzględnia się wpływ niektórych z wymienionych wyżej czynników. Przykładowo w pracy [18] uwzględniono wpływ warunków pogodowych, w artykule [19] wpływ pór roku, a w pracy [20] nawyki mieszkańców w połączeniu z charakterystyką używanych urządzeń gospodarstwa domowego. Z kolei w artykule [21] opisano metodę prognozowania dla budynków niskoemisyjnych, a w pracy [22] dla budynków z rozbudowaną automatyką sterującą urządzeniami. Wymienione metody wykorzystują zaawansowane techniki obliczeniowe, takie jak sieci neuronowe [18, 21, 22], uczenie maszynowe [20] lub optymalizację metaheurystyczną [19], w związku z tym są one zbyt skomplikowane, aby można było je łatwo zaimplementować w systemie HEMS. Zatem w tym obszarze zastosowań potrzebne jest opracowanie znacznie prostszej metody, która pozwoli na wyznaczenie krótkoterminowej prognozy bazowego obciążenia odbiorcy komunalno-bytowego cechującej się zadowalającą dokładnością, przy jednoczesnej minimalizacji zasobów obliczeniowych niezbędnych do jej sporządzenia. Jest to główny cel niniejszego artykułu.

Zaproponowana w artykule metoda prognozowania opiera się na założeniach metody naiwnej, przy czym w metodzie tej – oprócz wartości średniej obciążenia z kilku dni poprzedzających – do przygotowania prognozy


wykorzystano również inne sposoby opisu zmienności obciążenia (obciążenie „typowe” i statystycznie najczęstsze), omówione w dalszej części artykułu. Do kalibracji i walidacji metody wykorzystano dane pomiarowe pochodzące z liczników energii zainstalowanych u odbiorców z grupy taryfowej G11. Uzyskane wyniki prognoz porównano z wynikami otrzymanymi przy zastosowaniu metody naiwnej w wersji podstawowej (obciążenie średnie z kilku poprzednich dni). Finalnie, zaproponowany model prognostyczny zastosowano do wyznaczenia prognozy obciążenia bazowego wybranego odbiorcy.

Metoda naiwna w prognozowaniu obciążenia


Metoda naiwna nazywana jest również w literaturze angielskiej „persistence method” [23], co można przetłumaczyć jako „metoda trwałości”. To określenie dobrze odzwierciedla podstawę metody, którą jest założenie, że wszystko pozostanie bez zmian, czyli wartość prognozowana będzie taka sama jak ostatni pomiar. Zgodnie z tym założeniem obciążenie odbiorcy w godzinie h dnia n będzie takie samo jak obciążenie w tej samej godzinie w dniu poprzednim (wariant $n - 1$) lub w takim samym dniu tydzień temu (wariant $n - 7$). W innym wariantcie metody naiwnej wykorzystuje się kilka dni poprzedzających (kolejnych lub kolejnych takich samych), dla których obliczana jest wartość średnia obciążenia w poszczególnych godzinach, stanowiąca prognozę zapotrzebowania w analizowanym dniu n .

Propozycja metody prognozowania obciążenia odbiorcy komunalno-bytowego bazująca na metodzie naiwnej


Ponieważ obciążenie odbiorcy komunalno-bytowego jest silnie skorelowane z obecnością domowników i zwykle wykazuje pewną powtarzalność tygodniową, w niniejszym artykule zastosowane zostanie podejście oparte na wykorzystaniu kilku kolejnych takich samych dni poprzedzających (dni $n - 7$, $n - 14$, $n - 21$...). Na rys. 1 ÷ 4 dla wybranego odbiorcy komunalno-bytowego przedstawiono dobowe grafiki obciążenia dla czterech kolejnych wtorków. Dane te zostaną wykorzystane do zilustrowania zaproponowanej w artykule metody prognozowania zapotrzebowania.




Rys. 1. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 28$ (wtorek, 21.05.2019, zużycie dobowe 6,86 kWh)



Rys. 2. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 21$ (wtorek, 28.05.2019, zużycie dobowe 8,32 kWh)




Rys. 3. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 14$ (wtorek, 04.06.2019, zużycie 5,57 kWh)



Rys. 4. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 7$ (wtorek, 11.06.2019, zużycie dobowe 6,89 kWh)

W pierwszym kroku proponowanej metody, na podstawie zarejestrowanych profili obciążenia odbiorcy (rys. 1 ÷ 4), wyznacza się wartości średnie zużycia w poszczególnych godzinach doby, co ilustruje rys. 5.



Rys. 5. Średnie obciążenie odbiorcy komunalno-bytowego w poszczególnych godzinach wyznaczone dla czterech kolejnych wtorków (zużycie dobowe 6,91 kWh)

W metodzie naiwnej obliczone średnie obciążenia godzinowe stanowiłyby wprost prognozę zapotrzebowania w analizowanym dniu (w dniu n , czyli w tym przypadku we wtorek, 18.06.2019), co można wyrazić wzorem:


$$E_{np}(h) = E_{sr}(h) = \frac{1}{N} \sum_{i=1}^N E_{n-7i}(h), \quad (1)$$

gdzie:


- $E_{np}(h)$ - prognozowane zużycie energii w dniu n w godzinie h ,
- $E_{sr}(h)$ - średnie zużycie energii w godzinie h ,
- $E_{n-7i}(h)$ - zużycie energii w godzinie h w kolejnych takich samych dniach poprzedzających, $i = 1, 2, \dots, N$,
- N - liczba kolejnych takich samych dni poprzedzających, dla których wyznaczane jest zużycie średnie.

W niniejszym artykule do wyznaczenia prognozy zapotrzebowania proponuje się natomiast zastosowanie również innych niż grafik średni, sposobów opisu zmienności obciążenia odbiorcy. W tym celu wykorzystany zostanie tzw. grafik „typowy” oraz grafik statystycznie najczęstszy.

Metoda tworzenia „typowego” grafiku obciążenia odbiorcy została zaproponowana w pracy [24]. Polega ona na tym, że w pierwszej kolejności godzinowe zużycie energii w analizowanych N dniach, np. dla czterech wtorków pokazanych na rys. 1 ÷ 4, porządkuje się od wartości największej do najmniejszej. Następnie z tak uporządkowanych wartości oblicza się średnie dla poszczególnych godzin. W kolejnym kroku, obliczone średnie z wartości uporządkowanych przypisuje się do odpowiednich przedziałów czasowych, wykorzystując wyznaczone wcześniej średnie obciążenie odbiorcy dla wartości chronologicznych (rys. 5). Przypisanie polega na tym, że największą wartość średnią z uporządkowanych wartości obciążeń godzinowych przypisuje się do przedziału czasowego, w którym wystąpiła największa wartość średnia z obciążeń chronologicznych. Drugą największą wartość średnią z obciążeń uporządkowanych przypisuje się do godziny, w której wystąpiła druga z kolei największa wartość średnia z obciążeń chronologicznych, trzecią do trzeciej, itd., co zilustrowano na rys. 6. W efekcie otrzymuje się tzw. grafik „typowy” przedstawiony na rys. 7.




Rys. 6. Ilustracja metody tworzenia „typowego” grafiku obciążenia odbiorcy komunalno-bytowego



Rys. 7. „Typowe” obciążenie odbiorcy komunalno-bytowego w poszczególnych godzinach wyznaczone dla czterech kolejnych wtorków (zużycie dobowe 6,91 kWh)

W trzecim kroku proponowanej metody prognozowania zapotrzebowania tworzony jest grafik obciążeń statystycznie najczęściej występujących w poszczególnych godzinach doby (grafik statystycznie najczęstszy). W tym celu dla N analizowanych takich samych dni poprzedzających najpierw określa się maksymalną wartość godzinowego zużycia energii ($E_{max}(h)$), jakie wystąpiło w tym okresie. Następnie obliczane są granice poszczególnych przedziałów zużycia równe (mniejsza szerokość dwóch pierwszych przedziałów umożliwia zróżnicowanie bardzo niskich obciążeń): $(0, 0,05E_{max}(h)]$, $(0,05E_{max}(h), 0,1E_{max}(h)]$, $(0,1E_{max}(h), 0,2E_{max}(h)]$, $(0,2E_{max}(h), 0,3E_{max}(h)]$, ..., $(0,9E_{max}(h), E_{max}(h)]$. Dla tak zdefiniowanych przedziałów sprawdza się, ile razy obciążenie w danej godzinie w ciągu N analizowanych dni zawierało się w poszczególnych przedziałach i wyszukuje się przedział z największą liczbą zliczeń. Środek tego przedziału przyjmowany jest jako obciążenie statystycznie najczęściej występujące w danej godzinie doby w ciągu N analizowanych dni. Rysunek 8 przedstawia grafik statystycznie najczęstszy utworzony opisaną metodą dla czterech wtorków, dla których dobowe przebiegi obciążenia zostały zilustrowane na rys. 1 ÷ 4.



Rys. 8. Statystycznie najczęstsze obciążenie odbiorcy komunalno-bytowego w poszczególnych godzinach wyznaczone dla czterech kolejnych wtorków (zużycie dobowe 7,08 kWh)

Opracowane grafiki: średni (rys. 5), „typowy” (rys. 7) i statystycznie najczęstszy (rys. 8), określone dla N analizowanych takich samych dni poprzedzających, w kolejnym kroku są wykorzystywane do wyznaczenia prognozy zapotrzebowania dla rozpatrywanego dnia n . W tym celu dokonuje się odpowiedniego „złożenia” tych grafików z uwzględnieniem wag, co wyraża wzór:


$$E_{np}(h) = w_1 E_{sr}(h) + w_2 E_{typ}(h) + w_3 E_{st}(h), \quad (2)$$

gdzie:

- $E_{typ}(h)$ - „typowe” zużycie energii w godzinie h ,
- $E_{st}(h)$ - statystycznie najczęstsze zużycie energii w godzinie h ,

w_1, w_2, w_3 - wagi poszczególnych składników prognozy (należy pamiętać, że dla $w_1 = 1$ i $w_2 = w_3 = 0$ otrzymuje się model naiwny wyrażony wzorem (1)).

Na rys. 9 przedstawiono prognozę wygasła zapotrzebowania odbiorcy w dniu n (wtorek, 18.06.2019), określoną zaproponowaną metodą dla czterech kolejnych wtorków poprzedzających, przy założeniu jednakowych wag ($w_1 = w_2 = w_3 = 1/3$) poszczególnych składników prognozy.



Rys. 9. Prognoza wygasła zapotrzebowania na energię elektryczną w dniu n (wtorek, 18.06.2019) określona zaproponowaną metodą (zużycie rzeczywiste 8,44 kWh, zużycie prognozowane 6,97 kWh)

Zależność (2) definiuje, oparty na założeniach metody naiwnej, hybrydowy model prognostyczny, wykorzystujący historyczne dane pomiarowe. Model ten należy poddać odpowiedniej kalibracji, polegającej na określeniu optymalnej liczby kolejnych takich samych dni poprzedzających (N) oraz wag poszczególnych składników prognozy (w_1, w_2, w_3).

Kalibracja modelu prognostycznego

Do kalibracji (a następnie do walidacji) zaproponowanego modelu prognostycznego (2) wykorzystano roczne dane pomiarowe dotyczące zużycia energii dla dziesięciu wybranych odbiorców z obszaru miejsko-wiejskiego zlokalizowanych w promieniu 30 km. Wykorzystane dane miały rozdzielczość godzinową i pochodziły z liczników rozliczeniowych energii elektrycznej zainstalowanych u tych odbiorców. W tabeli 1 podano najważniejsze dane charakteryzujące rozpatrywanych odbiorców. Wybrani odbiorcy zostali losowo podzieleni na dwie równoliczne grupy. Dane pomiarowe dla odbiorców z grupy pierwszej (O1, O3, O4, O7 i O9) zostały wykorzystane do kalibracji modelu, natomiast dane dla odbiorców z grupy drugiej (O2, O5, O6, O8 i O10) do jego walidacji, co opisano w kolejnej części artykułu.

Tabela 1. Dane charakteryzujące odbiorców wykorzystanych do kalibracji i walidacji zaproponowanego modelu prognostycznego (2)

Odbiorca	Moc umowna, kW	Moc szczytowa (godzinowa), kW	Roczne zużycie energii, kWh
O1	6	3,21	3 978
O2	16	3,73	3 812
O3	20	5,54	3 737
O4	14	3,40	3 719
O5	15	3,58	3 649
O6	21	5,32	3 625
O7	17,3	3,54	3 537
O8	15	3,16	2 886
O9	5,7	3,28	2 720
O10	17,3	2,39	2 313

Kalibracja zaproponowanego modelu prognostycznego (2) polegała na dobraniu liczby kolejnych takich samych dni poprzedzających (N) oraz wartości wag (w_1, w_2, w_3) w taki sposób, aby zminimalizować błędy prognozy zapotrzebowania w dniu n , w stosunku do rzeczywistego zużycia, jakie wystąpiło w tym dniu. Poszukując optymalnych wartości N oraz w_1, w_2 i w_3 obliczano błędy zdefiniowane zależnościami:

$$MAE = \frac{1}{24} \sum_{h=1}^{24} |E_{nr}(h) - E_{np}(h)|, \quad (3)$$

$$RMSE = \sqrt{\frac{1}{24} \sum_{h=1}^{24} (E_{nr}(h) - E_{np}(h))^2}, \quad (4)$$

$$MAPE = \frac{1}{24} \sum_{h=1}^{24} \left| \frac{E_{nr}(h) - E_{np}(h)}{E_{nr}(h)} \right| \cdot 100\%, \quad (5)$$

gdzie:

$E_{nr}(h)$ - rzeczywiste zużycie energii w dniu n w godzinie h .

Kalibracja modelu (2) została wykonana dwuetapowo. W pierwszym etapie poszukiwano optymalnej liczby dni poprzedzających (N), przy przyjęciu jednakowych wartości wag poszczególnych składników prognozy ($w_1 = w_2 = w_3 = 1/3$). Obliczenia wykonano dla pięciu odbiorców, dla których losowo wybierano różne dni tygodnia (dni n) w różnych okresach roku. Prognozy dla tych dni były wyznaczane dla $N = 2, 3, \dots, 10$. Przykładowe wyniki obliczeń przedstawiono w tabeli 2 (wyłuszczone liczby dni poprzedzających, dla których uzyskano najmniejszą wartość błędu $MAPE$). Otrzymane wyniki wskazują, że liczba takich samych dni poprzedzających (N), dla których uzyskano najmniejsze wartości błędów określonych zależnościami (3) ÷ (5) wynosi zwykle od 3 do 5.

Tabela 2. Błędy prognozy uzyskane modelem prognostycznym (2) dla różnej liczby takich samych dni poprzedzających N

Odbiorca	Dzień prognozy (dzień n)	Liczba dni poprzedzających (N)	Błędy prognozy		
			MAE kWh	RMSE kWh	MAPE %
O3	08.08	2	0,13	0,25	30,17
		3	0,13	0,26	32,21
		4	0,13	0,25	29,82
		5	0,12	0,24	27,70
		6	0,13	0,25	33,93
		7	0,13	0,25	33,47
		8	0,14	0,26	34,55
		9	0,14	0,25	34,17
O4	12.06	10	0,14	0,26	34,68
		2	0,14	0,23	37,85
		3	0,12	0,20	33,33
		4	0,14	0,28	36,30
		5	0,16	0,28	37,48
		6	0,16	0,28	35,62
		7	0,16	0,28	37,46
		8	0,16	0,27	36,72
O9	02.11	9	0,16	0,26	38,51
		10	0,16	0,28	40,50
		2	0,19	0,23	34,95
		3	0,17	0,21	28,93
		4	0,16	0,22	25,43
		5	0,17	0,21	27,17
		6	0,15	0,21	25,62
		7	0,17	0,22	27,71
		8	0,17	0,21	26,64
		9	0,18	0,22	27,12
		10	0,19	0,24	28,90

W drugim etapie kalibracji wyznaczono optymalne wartości współczynników w_1 , w_2 i w_3 , przyjmując, że liczba takich samych dni poprzedzających N jest równa 3, 4 lub 5. Obliczenia wykonano przy zastosowaniu algorytmu optymalizacyjnego PSO (Particle Swarm Optimization) [25], przy założeniu, że funkcją celu jest minimalizacja błędu $MAPE$ (5), a wartości wag spełniają następujące ograniczenia: $w_1, w_2, w_3 \in [-1, 1]$, $w_1 + w_2 + w_3 = 1$. Przykładowe wyniki obliczeń zestawiono w tabeli 3. Analiza pełnego zbioru uzyskanych wyników wykazała, że dla większości przypadków $w_1 = 1$, a wartości w_2 i w_3 zawierają się zwykle w przedziale od -0,3 do 0,3 i mają taką samą wartość bezwzględną, ale przeciwne

znaki (w_2 częściej jest dodatni). Dla zoptymalizowanych wartości wag błędy $MAPE$ (tabela 3) osiągają niższe wartości, w porównaniu z wartościami uzyskanymi dla jednakowych współczynników wagowych (tabela 2).

Tabela 3. Wartości wag poszczególnych składników prognozy modelu (2) minimalizujące błąd $MAPE$

Odbiorca	Dzień prognozy (dzień n)	Liczba dni poprzedzających (N)	Wagi poszczególnych składników prognozy			MAPE %
			w_1	w_2	w_3	
O3	01.08	3	1,00	0,07	-0,07	23,16
		4	1,00	-0,11	0,11	23,49
		5	1,00	0,11	-0,11	21,97
	08.08	3	1,00	-0,05	0,05	28,43
		4	1,00	-0,07	0,07	27,86
		5	1,00	-0,05	0,05	25,54
O4	12.06	3	-0,04	1,00	0,04	25,64
		4	1,00	-0,07	0,07	32,77
		5	-0,10	1,00	0,10	32,45
	12.10	3	1,00	0,39	-0,39	29,54
		4	0,62	0,38	0,00	25,32
		5	0,27	0,60	0,13	27,80
O9	02.11	3	0,00	0,89	0,10	26,76
		4	-0,26	1,00	0,26	22,55
		5	0,10	0,96	-0,06	26,00
	07.12	3	1,00	-0,08	0,08	26,75
		4	1,00	0,17	-0,17	30,73
		5	1,00	-0,20	0,20	25,90

Walidacja modelu prognostycznego

Uwzględniając wyniki otrzymane podczas kalibracji modelu prognostycznego (2), przy jego walidacji przyjęto, że liczba takich samych dni poprzedzających (N) wynosi od 3 do 5, a współczynniki wagowe są równe $w_1 = 1$, $w_2 = 0,3$, $w_3 = -0,3$. Dla takich parametrów modelu wyznaczono prognozy dla odbiorców z drugiej grupy (O2, O5, O6, O8 i O10). Wartości błędów prognozy dla wybranych przypadków zestawiono w tabeli 4, przy czym, dla porównania, podano również wartości błędów uzyskane przy zastosowaniu metody naiwnej (1). W większości przeanalizowanych przypadków błędy prognozy uzyskane za pomocą zaproponowanego modelu (2), w szczególności błąd $MAPE$, były niższe niż błędy uzyskane dla metody naiwnej (1). Pozwala to wnioskować o przydatności zaproponowanego modelu do prognozowania bazowego obciążenia odbiorców komunalno-bytowych.

Tabela 4. Porównanie dokładności prognoz uzyskanych metodą naiwną (1) z prognozami uzyskanymi zaproponowanym modelem (2)


Odbiorca	Dzień prognozy n	Liczba dni poprzedzających N	Metoda naiwna (1)			Model prognostyczny (2)		
			MAE kWh	RMSE kWh	MAPE %	MAE kWh	RMSE kWh	MAPE %
O2	25.03	3	0,12	0,18	39,34	0,12	0,18	38,35
		4	0,11	0,17	34,39	0,11	0,17	32,72
		5	0,11	0,17	30,98	0,12	0,20	35,84
O5	29.05	3	0,17	0,28	34,62	0,20	0,35	35,47
		4	0,13	0,21	25,97	0,14	0,26	23,86
		5	0,10	0,17	20,77	0,08	0,11	17,15
O10	13.11	3	0,11	0,18	30,59	0,11	0,19	28,43
		4	0,11	0,18	30,30	0,11	0,19	29,68
		5	0,10	0,17	27,06	0,10	0,17	25,93

Zastosowanie zaproponowanego modelu prognostycznego do określania bazowego obciążenia odbiorcy komunalno-bytowego

W omówionych dotychczas badaniach korzystano z pomiarów zarejestrowanych przez liczniki rozliczeniowe należące do OSD. Wykorzystane pomiary stanowiły więc całkowite obciążenie analizowanych odbiorców, obejmujące zarówno ich obciążenia bazowe, na które składają się odbiorniki o niesterowanym czasie załączania (np. oświetlenie, lodówki, telewizory, komputery, kuchenki, drobny sprzęt AGD,

pompy obiegowe CO i CWU, itp.), jak i obciążenia dodatkowe (potencjalnie sterowalne), na które składają się odbiorniki, których czas załączenia można zaprogramować (pralki, zmywarki, suszarki do ubrań, bojler i grzejniki elektryczne, klimatyzatory, itp.). Dla takich pomiarów przeprowadzono kalibrację i walidację zaproponowanego modelu prognostycznego (2). Celem niniejszego artykułu jest opracowanie metody prognozowania bazowego (nie całkowitego) obciążenia odbiorcy komunalno-bytowego. W tej części przedstawiono wyniki działania zaproponowanego modelu prognostycznego (2) w tym zastosowaniu.

Do weryfikacji przydatności modelu (2) do prognozowania obciążenia bazowego wykorzystano wyniki pomiarów zarejestrowanych przez dedykowany system pomiarowy zainstalowany w budynku mieszkalnym należącym do jednego z autorów artykułu. System ten umożliwia rejestrację całkowitego obciążenia budynku, jak również rejestrację obciążenia odbiorników przeznaczonych do zdalnego załączania przez system HEMS (odbiorniki o sterowanym czasie załączania obejmują: zmywarkę, pralkę, suszarkę do ubrań oraz ładowarkę roweru elektrycznego). Zatem na podstawie takiego zbioru pomiarów można określić bazowe obciążenie budynku w poszczególnych dniach poprzedzających N , stanowiące podstawę do opracowania prognozy obciążenia bazowego w analizowanym dniu n . Przykładowe wyniki pomiarów, zarejestrowanych w sobotę, 31 sierpnia 2024 r., przedstawiono na rys. 10. W tym dniu obciążenie całkowite budynku wyniosło 19,32 kWh, a obciążenie bazowe było równe 15,94 kWh. Na obciążenie dodatkowe (3,38 kWh) złożyła się energia zużyta przez: zmywarkę (1,15 kWh), pralkę (0,5 kWh), suszarkę do ubrań (0,65 kWh) oraz ładowarkę roweru elektrycznego (1,05 kWh).



Rys. 10. Obciążenie bazowe oraz obciążenie dodatkowe (odbiorniki o sterowanym czasie załączania) analizowanego odbiorcy komunalno-bytowego w sobotę, 31 sierpnia 2024 r.


Efekty działania modelu prognostycznego (2) w zastosowaniu do prognozowania bazowego obciążenia odbiorcy komunalno-bytowego zostaną przedstawione na przykładzie prognoz wyznaczonych dla trzech kolejnych, takich samych dni roboczych (dni prognozy n obejmują środy: 3, 10 i 17 lipca 2024 r.). W obliczeniach przyjęto parametry modelu (2) podane w poprzedniej części artykułu. Prognozy wykonano dla $N = 3, 4, 5$ kolejnych takich samych dni poprzedzających. Wyniki podsumowujące przeprowadzone obliczenia zaprezentowano w tabeli 5. Z kolei na rys. 10 ÷ 13 porównano dobowe przebiegi zmierzzonego (rzeczywistego) obciążenia bazowego z przebiegami wyznaczonymi za pomocą modelu (2), dla $N = 5$ kolejnych takich samych dni poprzedzających.

Analizując uzyskane wyniki można zauważyć, że maksymalna różnica między rzeczywistym a prognozowanym bazowym zużyciem energii elektrycznej w rozpatrywanych dniach wynosi od 1 kWh do 1,6 kWh (około 10% zużycia dobowego). Z kolei błędy $MAPE$ zawierają się w przedziale od 20% do 30%. Otrzymana dokładność prognozy jest porównywalna z dokładnością, którą inni autorzy uzyskali dla tego rodzaju zadania prognostycznego (prognozowanie zapotrzebowania pojedynczego odbiorcy komunalno-bytowego) z wykorzystaniem znacznie bardziej zaawansowanych metod, opartych na sztucznych sieciach neuronowych. Przykładowo, błędy $MAPE$ dla prognoz dobowych dla okresu


rocznego, uzyskane dla 42 przeanalizowanych odbiorców przy wykorzystaniu metody zaproponowanej w artykule [26], zawierały się zwykle w granicach od 30% do 50%. Z kolei analizy wykonane w artykule [27] dla 1181 odbiorców wskazują, że dla odbiorców o największej zmienności obciążenia w tej grupie dobowe błędy $MAPE$ w miesiącu o najwyższym zapotrzebowaniu w ciągu roku kształtowały się na poziomie od kilkunastu do nawet 100%. Zatem dokładność prognoz bazowego obciążenia odbiorcy uzyskiwana z wykorzystaniem zaproponowanego modelu (2) jest zadowalająca, aby zaproponowana metoda mogła zostać zastosowana w systemie HEMS, służącym do zarządzania energią elektryczną w budynku mieszkalnym wyposażonym w źródło fotowoltaiczne, magazyn energii i sterowane odbiorniki.

Tabela 5. Rzeczywiste i prognozowane bazowe zużycie energii oraz błędy prognoz obciążenia bazowego odbiorcy komunalno-bytowego uzyskane przy zastosowaniu zaproponowanego modelu (2)


Dzień prognozy n	Liczba dni poprzedzających N	Bazowe zużycie energii		Błędy prognozy		
		rzeczywiste, kWh	prognozowane, kWh	MAE kWh	RMSE kWh	MAPE %
03.07	3	11,79	10,92	0,13	0,18	25,34
	4		10,87	0,14	0,21	24,89
	5		10,84	0,12	0,19	22,30
10.07	3	12,49	11,89	0,11	0,16	23,00
	4		11,18	0,11	0,15	20,73
	5		10,88	0,10	0,14	18,14
17.07	3	12,39	12,36	0,16	0,24	29,80
	4		11,88	0,15	0,23	27,19
	5		11,29	0,16	0,25	27,25



Rys. 11. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę, 3 lipca 2024 r.



Rys. 12. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę, 10 lipca 2024 r.



Rys. 13. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę, 17 lipca 2024 r.

Podsumowanie

Dobowe profile zapotrzebowania na energię elektryczną indywidualnych odbiorców komunalno-bytowych charakteryzują się dużą zmiennością, wynikającą z różnorodności zachowań tych odbiorców, stymulowanych dodatkowo przez szeroką gamę czynników zewnętrznych. W efekcie prognozowanie tego rodzaju przebiegów z odpowiednio wysoką dokładnością jest zadaniem skomplikowanym, wymagającym

często wykorzystania zaawansowanych metod obliczeniowych, bazujących na szerokim zakresie danych wejściowych. To sprawia, że tak rozbudowane metody mogą stwarzać problemy w zastosowaniu w budynkowych systemach zarządzania energią HEMS. Istnieje zatem konieczność poszukiwania prostszych rozwiązań, które jednocześnie będą cechowały się odpowiednią, do tego zastosowania, jakością generowanych prognoz.

W artykule zaproponowano metodę prognozowania zapotrzebowania odbiorcy komunalno-bytowego opartą na idei metody naiwnej, która do obliczeń wykorzystuje godzinowe pomiary zużycia energii z kilku takich samych dni poprzedzających. Na podstawie takiego zestawu pomiarów wyznaczane są przebiegi opisujące w różny sposób dobowe obciążenie analizowanego odbiorcy: grafik średni, tzw. grafik „typowy” i grafik statystycznie najczęstszy, a prognoza wyznaczana jest przez zsumowanie powyższych grafików, z uwzględnieniem odpowiednich wag.

Zaproponowany model prognostyczny został skalibrowany przy wykorzystaniu rzeczywistych danych pomiarowych pochodzących z liczników rozliczeniowych odbiorców należących do grupy taryfowej G11. Liczba takich samych

dni poprzedzających, dla których uzyskano największą dokładność prognozy wynosi od 3 do 5. Wagi, z którymi sumowane są poszczególne składniki prognozy, wyznaczone przy użyciu metody optymalizacji PSO, są niejednakowe. Największą wagę ma grafik średni. Wagi dwóch pozostałych składników – grafiku „typowego” i statystycznie najczęstszego – są niższe oraz mają jednakową wartość bezwzględną, ale przeciwne znaki. Tak skalibrowany model dał błędy porównywalne z innymi, bardziej zaawansowanymi modelami. Dzięki prostocie opracowanego modelu prognostycznego istnieje możliwość jego praktycznej implementacji w systemie HEMS, zarządzającym energią w budynku wyposażonym w źródło fotowoltaiczne, magazyn energii i sterowane odbiorniki.

Autorzy: mgr inż. Tomasz Naczyński, Politechnika Śląska, Wspólna Szkoła Doktorów, ul. Akademicka 2a; dr hab. inż. Roman Korab, prof. PŚ, Politechnika Śląska, Wydział Elektryczny, Katedra Elektroenergetyki i Sterowania Układów, ul. Krzywoustego 2, 44-100 Gliwice, E-mail: roman.korab@polsl.pl; dr inż. Marcin Połomski, Politechnika Śląska, Wydział Automatyki, Elektroniki i Informatyki, Katedra Algorytmiki i Oprogramowania, ul. Akademicka 16, 44-100 Gliwice, E-mail: marcin.polomski@polsl.pl

LITERATURA

- [1] Zafar U., Bayhan S., Sanfilippo A.: Home Energy Management System: Concepts, Configurations, and Technologies for the Smart Grid. IEEE Access, 8/2020, doi:10.1109/ACCESS.2020.3005244
- [2] Korab R., Kandzia T., Naczyński T.: Short-term forecasting of photovoltaic power generation. Przegląd Elektrotechniczny, 9/2023, doi:10.15199/48.2023.09.06
- [3] Korab R., Połomski M., Naczyński T.: Optimal Scheduling of Energy Storage and Shiftable Loads in Grid-Connected Residential Buildings with Photovoltaic Micro-Installations. Energies 2024, 17, 5264, doi:10.3390/en17215264
- [4] Esteves G., Bastos B., Cyrino F., Calili R., Souza R.: Long Term Electricity Forecast: A Systematic Review. Procedia Computer Science, vol. 55, 2015, doi:10.1016/j.procs.2015.07.041
- [5] Khuntia S., Rueda J., van der Meijden M.: Forecasting the load of electrical power systems in mid- and long-term horizons: a review. IET Gener. Transm. Distrib., vol. 10, 2016, doi:10.1049/iet-gtd.2016.0340
- [6] Rodrigues F., Cardeira C., Calado J., Melicio R.: Short-Term Load Forecasting of Electricity Demand for the Residential Sector Based on Modelling Techniques: A Systematic Review. Energies 2023, 16, doi:10.3390/en16104098
- [7] Jiang Y., Gao T., Dai Y., Si R., Hao J., Zhang J., Gao D.: Very short-term residential load forecasting based on deep-autoformer. Applied Energy, vol. 328, 2022, doi:10.1016/j.apenergy.2022.120120
- [8] Pinheiro M., Madeira S., Francisco A.: Short-term electricity load forecasting – A systematic approach from system level to secondary substations. Applied Energy, vol. 332, 2023, doi:10.1016/j.apenergy.2022.120493
- [9] Tran L., Cai G., Gao W.: Determinants and approaches of household energy consumption: A review. Energy Reports, 10/2023, doi:10.1016/j.egyr.2023.08.026
- [10] Dąsał K., Popławski T., Starczynowska E.: Badanie wpływu czynników pozapogodowych na zmiany obciążenia w KSE. Rynek Energii, 2/2010
- [11] Kang J., Reiner D.: What is the effect of weather on household electricity consumption? Empirical evidence from Ireland, Energy Economics, vol. 111, 2022, doi:10.1016/j.eneco.2022.106023
- [12] Yang L., Yan H., Lam J.: Thermal comfort and building energy consumption implications – A review. Applied Energy, vol. 115, 2014, doi:10.1016/j.apenergy.2013.10.062
- [13] Abrahamse W., Steg L., Vlek C., Rothengatter T.: A review of intervention studies aimed at household energy conservation. Journal of Environmental Psychology, vol. 25, 3/2005, doi:10.1016/j.jenvp.2005.08.002
- [14] Steg L., Vlek C.: Encouraging pro-environmental behavior: An integrative review and research agenda. Journal of Environmental Psychology, 3/2009, doi:10.1016/j.jenvp.2008.10.004
- [15] Tuomela S., de Castro Tomé M., Iivari N., Svento R.: Impacts of home energy management systems on electricity consumption. Applied Energy, vol. 299, 2021, doi:10.1016/j.apenergy.2021.117310
- [16] Hofmann M., Lindberg K.: Residential demand response and dynamic electricity contracts with hourly prices: A study of Norwegian households during the 2021/22 energy crisis. Smart Energy, vol. 13, 2024, doi:10.1016/j.segy.2023.100126.
- [17] www.pse.pl/jak-funkcjonuje-krajowy-system-elektroenergetyczny/wsparcie-bilansowania-systemu
- [18] Wang Y., Zhang N., Chen X.: A Short-Term Residential Load Forecasting Model Based on LSTM Recurrent Neural Network Considering Weather Features. Energies 2021, 14, doi:10.3390/en14102737
- [19] Barman M., Dev Choudhury N.: Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept. Energy, vol. 174, 2019, doi:10.1016/j.energy.2019.03.01
- [20] Wang S., Deng X., Chen H., Shi Q., Xu D.: A bottom-up short-term residential load forecasting approach based on appliance characteristic analysis and multi-task learning. Electric Power Systems Research, vol. 196, 2021, doi:10.1016/j.epsr.2021.107233
- [21] Alanazi M., Saeed A., Islam M., Habib S., Sherazi H., Khan S., Shees M.: Enhancing Short-Term Electrical Load Forecasting for Sustainable Energy Management in Low-Carbon Buildings. Sustainability 2023, 15, 16885. doi:10.3390/su152416885
- [22] Su Y., He Q., Chen J., Tan M.: A residential load forecasting method for multi-attribute adversarial learning considering multi-source uncertainties. International Journal of Electrical Power & Energy Systems, vol. 154, 2023, doi:10.1016/j.ijepes.2023.109421
- [23] Kychkin A., Chasparis G.: Feature and model selection for day-ahead electricity-load forecasting in residential buildings. Energy and Buildings, vol. 249, 2021, doi:10.1016/j.enbuild.2021.111200
- [24] Berent-Żesławska J., Smajek L., Sobieszkański S.: Katalog odbiorców nN i SN. Opracowanie Zakładu Sieci Rozdzielczych Instytutu Energetyki, Katowice, 1995
- [25] Korab R., Połomski M., Naczyński T., Kandzia T.: A dynamic thermal model for a photovoltaic module under varying atmospheric conditions. Energy Conversion and Management, vol. 280, 2023, doi:10.1016/j.enconman.2023.116773
- [26] Yang W., Shi J., Li S., Song Z., Zhang Z., Chen Z.: A combined deep learning load forecasting model of single household resident user considering multi-time scale electricity consumption behavior. Applied Energy, vol. 307, 2022, doi:10.1016/j.apenergy.2021.118197
- [27] Acharya S.K., Wi Y.-M., Lee J.: Short-Term Load Forecasting for a Single Household Based on Convolution Neural Networks Using Data Augmentation. Energies 2019, 12, 3560, doi:10.3390/en12183560

Article

Optimal Scheduling of Energy Storage and Shiftable Loads in Grid-Connected Residential Buildings with Photovoltaic Micro-Installations

Roman Korab ^{1,*} , Marcin Połomski ²  and Tomasz Naczyński ³ 

¹ Department of Power Systems and Control, Faculty of Electrical Engineering, Silesian University of Technology, 44-100 Gliwice, Poland

² Department of Algorithmics and Software, Faculty of Automatic Control, Electronics and Computer Science, Silesian University of Technology, 44-100 Gliwice, Poland; marcin.polomski@polsl.pl

³ Joint Doctoral School, Silesian University of Technology, 44-100 Gliwice, Poland; tomasz.naczynski@polsl.pl

* Correspondence: roman.korab@polsl.pl

Abstract: Photovoltaic (PV) systems are becoming increasingly popular, especially in residential buildings. However, the high penetration of prosumer PV micro-installations can have a negative impact on the operation of distribution networks due to the low self-consumption of the energy produced. One way to mitigate this problem is to use a residential energy storage system (RESS) and load shifting under a demand-side management (DSM) scheme. Energy management systems (EMSs) are used to control the operation of RESSs and to implement DSM. There are two main categories of EMSs: rule-based and optimization-based. Optimization-based EMSs provide better results than rule-based EMSs but can be computationally expensive. This article proposes an optimization-based EMS that is designed specifically for residential buildings. The proposed home energy management system (HEMS) uses a particle swarm optimization method to maximize the prosumer's financial neutrality, which is calculated based on dynamic energy prices. Simulation-based evaluation using the measurements taken in a building equipped with a PV source, RESS, and shiftable loads shows the improved performance of the proposed HEMS compared to rule-based RESS control. The results show that the designed HEMS increases self-consumption, thus reducing the impact of the prosumer's PV micro-installations on the distribution grid.



Citation: Korab, R.; Połomski, M.; Naczyński, T. Optimal Scheduling of Energy Storage and Shiftable Loads in Grid-Connected Residential Buildings with Photovoltaic Micro-Installations.

Energies **2024**, *17*, 5264. <https://doi.org/10.3390/en17215264>

Academic Editor: Branislav Hredzak

Received: 27 September 2024

Revised: 17 October 2024

Accepted: 20 October 2024

Published: 23 October 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Keywords: photovoltaic micro-installation; residential building; prosumer; self-consumption; energy storage; load-shifting; home energy management system; dynamic energy prices; particle swarm optimization

1. Introduction

Photovoltaic (PV) technology has evolved in recent decades into a major worldwide renewable generation technology [1]. By the end of 2022, the global cumulative installed capacity of PV systems reached 1177 GW and experienced 25% growth compared to 2021 [2]. Solar power contributes an increasing share of total electricity demand, accounting for 4.5% of global power production in 2022, up from 3.7% in the previous year. The reasons for this spectacular growth result from the unmatched versatility of PV technology, which can be applied in comparatively quickly deployed utility-scale projects at a competitive low cost and can generate energy for individual customers by means of rooftop micro-installations, increasing their self-sufficiency. Globally, the share of the rooftop segment has been growing continuously since 2018 and, in 2022, both marked segments were balanced, with 48% of new capacity on rooftops [3]. One of the markets with the fastest growing segment of rooftop PV installations is Poland, where the growth has been primarily driven by prosumer systems below 50 kW. In 2022, Poland's rooftop segment was responsible for 78% of the installed PV capacity. In the third quarter of 2023, there were more than

1,322,000 prosumer micro-installations in operation, with a total installed capacity of more than 10 GW [4].

The economy, combined with growing ecological awareness, is the most common factor in the decision to install a prosumer PV source [5]. On the other hand, the current regulatory framework favors self-consumption as the only economically viable model for rooftop PV installations [6]. Considering this, prosumers should select the rated power of their PV plants so that their annual generation is approximately equal to the annual electricity consumption of their households [7]. Since the capacity factor of the PV source is low (it ranges from 10% in Europe to 20% in Latin America [8], and in Poland, it is about 11% [9]), producing energy equal to the consumer's annual demand requires the installation of a PV source of sufficiently large power rating. With an average annual consumption in the EU household sector of 1671 kWh per capita [10], the power of a PV source should be equal to 1.9 kW per capita. The PV micro-installation capacity determined in this way is much larger than a typical household load [11]. In addition, load and generation profiles are usually divergent [12]. As a result, most of the energy produced is fed into the power system to be taken back from it later.

The high penetration of PV micro-installations can have a negative impact on the operation of distribution networks [13]. One way to eliminate it is to curtail the active power generation of PV sources when it becomes problematic. Smart inverters can first reduce the output power and may eventually shut down a micro-installation to mitigate adverse effects on the network [14]. However, this is an unfavorable remedy that limits the economic and environmental benefits of solar energy production. An alternative technique is to reduce the amount of energy injected by prosumers into the power system when the PV sources are operating by using a residential energy storage system (RESS) and load shifting under a demand-side management (DSM) scheme.

RESSs can decrease PV curtailment by storing excess generation and, therefore, can reduce the export of energy to the network [15]. Currently, battery-based energy storage systems are predominantly employed [16]. To maximize effectiveness, the battery should be charged during high PV production, when the risk of exceeding the normal operating conditions of the network is at its highest [17]. However, reducing PV curtailment is not the sole purpose of installing an RESS. An additional benefit of battery installation results from serving the household load with stored PV energy. Another option to decrease PV curtailment is DSM, which has the potential to be a practical solution in all energy demand sectors, including residential buildings [18]. In this case, DSM mostly refers to the active shifting of household loads to increase matching demand with the power production. To obtain the best results from the use of RESS and DSM, the prosumer should properly control the operation of the storage and flexible loads through an energy management system (EMS).

There are two main categories of EMSs [19]: rule-based EMSs and optimization-based EMSs. A rule-based EMS allocates the resources using predefined logical rules so that the energy produced can be adequately used or stored. An optimization-based EMS is more sophisticated and usually implements an optimization-based unit commitment (UC) model that considers several technical constraints while optimizing the objective function. The authors of article [19] compared these two approaches by controlling a microgrid testbed equipped with controllable load banks, a battery, a diesel genset, and wind energy as well as PV simulators and generators. Article [20], on the other hand, compared the employment of these methods to control the operation of a microgrid in an office building supplied by PV and wind sources, as well as by various storage units. In both cases, the optimization-based EMS minimized the operating costs of the microgrid. The optimization problem formulated in [19] has been decomposed into UC and optimal power flow (OPF) problems [21]. A mixed-integer linear programming (MILP) method was used to solve the UC problem, while the OPF problem was solved using an interior-point nonlinear programming method. The MILP method was also used in [20].

Articles [19,20] considered microgrids with relatively large source and load capacities. In turn, article [22] compared these methods to control the energy flexibility in a single residential building with PV. The flexible sources included were a heat pump with an auxiliary electric resistance heater and a water tank, a battery, and shiftable loads (SLs), such as washing machines. Under the rule-based control, the PV's self-consumption was maximized, and the building acted as a customer who actively tried to avoid supplying PV electricity to the grid and did so only when other options were unsuccessful. If there was surplus PV power available, the energy was self-consumed in the following priority: firstly, shiftable appliances were operated; secondly, the remaining surplus was stored in the battery; and lastly, the remaining surplus was converted to heat and stored. At times when the PV power did not cover all consumption, the battery was discharged, and only the deficit was drawn from the grid. The second control approach analyzed in [22] was the cost-optimal control, which minimizes the total electricity cost to the building. In this mode, the building takes the role of an active prosumer that both buys and sells electricity. The electricity cost is minimized over sequential 24 h horizons using a deterministic dynamic programming (DP) algorithm. A similar optimization algorithm was applied in the article [23], in which the battery's state of charge (SoC) was chosen as the decision variable to maximize the user's profit. The proposed optimization-based control method was compared with the rule-based method in simulations conducted for a residential building equipped with a PV source and storage unit. An analogous comparison was made in the paper [24], with the MILP method being used to optimally control the energy storage and heat pump. The objective was to minimize costs and peak power while considering the thermal comfort of the residents of the building.

In the articles discussed above, various objective functions and optimization algorithms were used to control EMSs. In each case, better results were obtained for optimization-based EMSs than for rule-based EMSs. However, when applying the optimization-based control, the computation time can be long [21] and is highly dependent on the flexible sources included [22] and the simulation time step assumed [23]. As a result, high-performance computing may be required. This may be a significant obstacle to implementing optimization-based control into EMSs in residential buildings. Therefore, it is necessary to search for optimization methods that provide adequate results without having such high computational requirements. This is the purpose of this article.

The remainder of this study is organized as follows. In Section 2, a method for the optimal control of RESSs and SLs that maximizes the prosumer's financial neutrality is proposed. Section 3 presents a test installation located in a residential building equipped with a rooftop PV source, an RESS, and controllable household appliances, where field measurements were taken to test and validate the proposed method. The simulation results are shown and discussed in Section 4. Section 5 describes the architecture and framework of the proposed optimization-based EMS. Finally, the main contributions of the presented work and the conclusion are given in Section 6.

2. Control Algorithm for Maximizing the Prosumer's Financial Neutrality

The above-mentioned challenges and current trends indicate the need to look for a simple, scalable system that can be widely applied in residential buildings in order to spread the concept of renewable energy based on PV technology. Of particular importance in this system is a method for adequately controlling the operation of RESSs and flexible loads, which consequently leads to the search for a suitable EMS system that, at its core, contains a dedicated algorithm whose task is to optimally control devices for a predetermined objective function. While rule-based management strategies continue to be developed and refined [25], management strategies using novel approaches based on various computational intelligence tools are gaining popularity and attention from researchers [26]. In particular, extensive applications of artificial intelligence techniques to hybrid microgrids based on renewable energy sources have been highlighted, addressing problems such as multi-criteria optimization, demand and supply forecasting, energy management [27], as

well as fault detection, classification, and security [28]. A variety of techniques have been applied in this regard, such as machine learning, genetic algorithms, neural networks, swarm intelligence methods, and others. Among these, the multi-agent metaheuristic algorithms, such as particle swarm optimization (PSO), are especially gaining in popularity.

PSO is a stochastic population-based meta-heuristic optimization method inspired by swarm intelligence, such as the social behavior of bird flocking. It mimics the cooperative behavior of birds in a flock, where individual birds work together to find food and protect themselves from predators. Its first application to optimization problems was proposed by Kennedy and Eberhart [29], and it has since been successfully applied in many fields [30].

In general, the optimization problem considered in this paper can be defined as:

$$\min_{\mathbf{x}} f(\mathbf{x}), \quad (1)$$

where $f: \mathbb{R}^N \rightarrow \mathbb{R}$ is the objective function, and vector $\mathbf{x} \in \mathbb{R}^N$ represents the problem's decision variables. The problem described by Equation (1) is treated as an unconstrained optimization problem. However, only solutions belonging to a subset of the search space are considered admissible. The feasible subset of the search space is defined as follows:

$$\Omega = [x_1^l, x_1^u] \times [x_2^l, x_2^u] \times \cdots \times [x_N^l, x_N^u] \subset \mathbb{R}^N, \quad (2)$$

where x_j^l and x_j^u are, respectively, the lower and upper bounds of the search space along dimensions j , for $j = 1, 2, \dots, N$, where N is the number of decision variables.

PSO employs a swarm of particles, each representing a potential solution to an optimization problem. In a swarm of size M , these potential solutions are denoted by the particles' current positions:

$$\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T, \text{ for } i = 1, 2, \dots, M, \quad (3)$$

where $\mathbf{x}_i$ is the position of the i -th particle. Each particle i , in addition to its position vector $\mathbf{x}_i$, also has a velocity vector $\mathbf{v}_i$, defined as:

$$\mathbf{v}_i = [v_{i1}, v_{i2}, \dots, v_{iN}]^T, \text{ for } i = 1, 2, \dots, M. \quad (4)$$

Additionally, the particles maintain the value of their most favorable personal position so far, represented by $\mathbf{p}_i$. The overall best position $\mathbf{g}$ found by any particle in the swarm, known as the swarm leader, is also tracked.

During the iterative optimization process, the best position of each particle $\mathbf{p}_i$ is maintained or updated. An update occurs when the particle's new position yields a smaller value of the objective function. For the i -th particle, the value of its personal best position $\mathbf{p}_i^k$ in the k -th iteration is updated according to the following rule:

$$\mathbf{p}_i^k = \begin{cases} \mathbf{x}_i^k & \text{if } f(\mathbf{x}_i^k) < f(\mathbf{p}_i^{k-1}) \\ \mathbf{p}_i^{k-1} & \text{if } f(\mathbf{x}_i^k) \geq f(\mathbf{p}_i^{k-1}) \end{cases}. \quad (5)$$

For iteration k , based on the personal best positions of all particles $\{\mathbf{p}_1^k, \mathbf{p}_2^k, \dots, \mathbf{p}_M^k\}$, the swarm leader $\mathbf{g}$ is selected using the formula:

$$\mathbf{g}^k = \arg \min f(\{\mathbf{p}_i^k\}), \text{ for } i = 1, 2, \dots, M, \quad (6)$$

where $\mathbf{g}^k$ represents the best position discovered by any of the particles at iteration k .

The algorithm proceeds iteratively and, during this process, particles traverse the search space, considering their individual optimal position as well as the collective best

position. The velocity and position of each particle are updated based on these factors. At iteration k , for each particle i , its velocity is updated first, using the following formula:

$$\mathbf{v}_i^{k+1} = \chi \left(\mathbf{v}_i^k + c_1 \mathbf{r}_1^k (\mathbf{p}_i^k - \mathbf{x}_i^k) + c_2 \mathbf{r}_2^k (\mathbf{g}^k - \mathbf{x}_i^k) \right). \quad (7)$$

The particle's velocity is then restricted to predetermined minimum and maximum values (v_{min} and v_{max}) [31], followed by updating its position:

$$\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1}, \quad i = 1, 2, \dots, M, \quad (8)$$

where $\mathbf{r}_1$ and $\mathbf{r}_2$ are N -dimensional vectors of uniformly distributed random numbers within the range $[0, 1]$, c_1 and c_2 are acceleration coefficients, and χ is the so-called constriction factor [32]. Factors c_1 and c_2 determine the range of particle motion in an iteration. In most cases, they are identical.

In the optimization problem discussed in this article, each particle represents an RESS operating profile for an assumed 24 h time horizon. It also stores values representing the switching time of the SLs. This means that each particle has 25 elements (parameters), of which the first 24 elements represent the operating points of the RESS in the subsequent hours of the day, and the last element represents the time of switching on the SL (it was assumed that the SL can be switched on at any hour of the day, but its operation must be completed within the analyzed 24 h time horizon). During the optimization process, the PSO algorithm utilizes OpenDSS simulation software (version 9.6.1.1) [33], which uses a model of a building's power supply system implemented specifically for the purpose of the optimization procedure (the model is described in Section 3).

Figure 1 illustrates the sequence of steps of the PSO algorithm and how it interacts with the OpenDSS environment. During the algorithm initialization, an initial swarm (3) is generated. The values of swarm particles are randomly chosen from a set of permissible solutions. Furthermore, each particle is assigned a randomized initial velocity value (4). Then, during the initialization stage, the algorithm computes the objective function value for every particle, which also serves as its initial best value. Based on these, the swarm leader is determined (6). After the initialization step, the algorithm progresses to the iterative phase. In each iteration, after determining the velocity of the particles (7) and restricting them to their limiting values, new positions of the particles are calculated (8) while respecting their permissible values. Based on the new positions of the particles, the input OpenDSS model is modified. The primary algorithm initiates the simulation process, which is executed by the OpenDSS simulation engine. Based on the result of the simulations, an objective function value is calculated. Once the objective function values are determined, the best positions of each particle in the swarm are updated (5), and the leader of the swarm is selected (6). If the termination condition is not met, the algorithm will continue its operation in a loop, and the described process will be repeated.




Figure 1. PSO-based optimization algorithm flowchart.

From the standpoint of the problem examined in this article, specifically the optimization of the operation of the RESS and SLs and the general optimization problem formulated

by Equation (1), it is crucial to properly define the objective function's form. According to the European Commission's regulation establishing a guideline on electricity balancing [34], the settlement processes should ensure the financial neutrality of all Transmission System Operators. An analogous principle was adopted in this article for the selection of the objective function for the problem of optimizing the operation of the RESS and SLs. It was assumed that the goal of the optimization was to maximize the daily financial neutrality of the prosumer. This could be achieved by minimizing the objective function f , defined by the formula:

$$f = \sqrt{\sum_{h=1}^{24} (c_h P_{EX,h})^2}, \quad (9)$$

where $P_{EX,h}$ is the power exchange with the grid in hour h , and c_h is the energy price in hour h . The value of the power exchange with the grid in hour h can be calculated using the following formula:

$$P_{EX,h} = P_{FIX,h} + P_{SHIFT,h} - P_{PV,h} - P_{RESS,h}, \quad (10)$$

where $P_{FIX,h}$ and $P_{SHIFT,h}$ are fixed and shiftable loads, respectively; $P_{PV,h}$ is the PV source generation; and $P_{RESS,h}$ is the energy storage operation point. The value of $P_{RESS,h}$ can be positive or negative (a positive sign indicates discharging, and a negative sign indicates charging the battery). Therefore, by controlling the operating point of RESS and the switching time of the SLs, it is possible to change the value of the power exchange with the grid in individual hours and, as a result, the value of the optimized objective function (9).

Dynamic energy prices, changing on an hourly basis, were assumed to be used in the calculations. This is the preferred method of settling transactions in the energy market in the European Union [35]. The 24 h horizon, on the other hand, is a realistic optimization horizon in terms of day-ahead electricity price and weather forecast availability. Dynamic energy prices can have a positive or negative value (negative energy prices indicate a general need to increase the flexibility of the power system; in the case of prosumers, this phenomenon should stimulate an increase in self-consumption, e.g., by storing energy or increasing load by switching on additional shiftable loads). Power exchange with the grid can also be positive (import from the grid) or negative (export to the grid). As a result, the products of price and power appearing in the formula (9) can also be positive or negative, representing cost or income (Table 1). By squaring these products, the prosumer's cost and income are both minimized. In this way, the prosumer's financial neutrality is maximized. The application of the square root ensures better convergence of the optimization algorithm.

Table 1. Combinations of energy price and power exchange with the grid resulting in a cost or income for the prosumer.

Quantity/Value		Power Exchange with the Grid	
		Positive	Negative
Energy price	Positive	Cost	Income
	Negative	Income	Cost

3. Overview of a Test Installation and Input Data

The simulations carried out to test the proposed optimization method were based on measurements taken in a real residential detached house located in southern Poland. The building was inhabited by four people, and the annual electricity consumption was approximately 5000 kWh. The house was equipped with a rooftop PV micro-installation with a rated power of 5.25 kW and a Li-ion battery RESS with a rated power of 5 kW and a capacity of 20.8 kWh. The battery minimum SoC was set to 10%, while the maximum SoC was 100%. There were typical electrical appliances in the household, among which, the washing machine, clothes dryer, and dishwasher could be used as SLs. Dedicated

energy meters were installed in the building's power supply system to monitor PV generation, storage operation, total load, and power exchange with the grid. The results of the measurements were recorded with a 1 min resolution.

Figures 2 and 3 show the operation of the building's power supply system for two consecutive weekdays in September 2023 (all figures in the article use Coordinated Universal Time or UTC; in the summer in Poland, local time is UTC +02.00). No central EMS was used when the measurements were taken, as the RESS was being controlled by its own rule-based algorithm that minimized the power exchange with the grid. In addition, no DSM was used during the measurements.




Figure 2. PV generation, total load, RESS operation, and power exchange with the grid on 20 September 2023, recorded at 1 min resolution in the analyzed residential building.




Figure 3. PV generation, total load, RESS operation, and power exchange with the grid on 21 September 2023, recorded at 1 min resolution in the analyzed residential building.

The days of 20 September (Wednesday) and 21 September (Thursday) were selected for evaluating the proposed optimization method due to their similar PV generation and load profiles. The operation of the RESS, which was fully charged around noon, was also similar. On both days, the operation of a potential SL could also be observed in the afternoon, after the PV source generation was completed. However, significant differences in the profiles of hourly electricity market prices were recorded on these days [36], as shown in Figure 4. The 21 September price profile had a typical shape, with stable prices during the day and higher prices in the evening peak. In contrast, the 20 September price profile showed a significant reduction in energy prices between 9 a.m. and 2 p.m., with negative prices between 10 a.m. and 1 p.m. This was the result of the high generation of renewable energy sources, particularly PV sources, during these hours [37]. The described common features

and differences for the chosen days allowed us to assess the impact of energy prices on the results of optimizing the operation of the RESS and SLs.




Figure 4. Hourly electricity market prices on 20 September and 21 September 2023 used in simulations (1 EUR is approximately 4.5 PLN).

Since electricity prices are quoted with an hourly resolution, all the simulations described in this article were carried out with an hourly resolution. The hourly energy balances also corresponded to the net-billing system, which was in use in Poland. Thus, the daily operating profiles of the building's power supply system recorded at 1 min resolution (Figures 2 and 3) had to be transformed to an hourly resolution. Hourly power values were determined in such a way that the hourly energy quantities for 1 min and hourly resolution were equal. Figures 5 and 6 show the recorded daily profiles transformed to hourly resolution. The power consumed by the electrical appliances (washing machine in Figure 5 and dishwasher in Figure 6), treated as SLs in the simulations, is marked with green bars.




Figure 5. PV generation, total load, RESS operation, and power exchange with the grid on 20 September 2023, transformed to hourly resolution.

Simulations were carried out using a model of the building's power supply system implemented in OpenDSS software [33]. The model built in the OpenDSS environment considered the actual parameters of individual devices and their most important constraints, such as the SoC constraints for the RESS. An electrical topology in which the loads (shiftable and fixed), the RESS, and the PV source were connected to the single AC bus, which was directly connected to the low voltage (LV) grid, was employed (Figure 7). The measured operating profiles of the individual components of the building's power supply system were used to tune the model. During the simulations, the daily profiles of loads (fixed P_{FIX} and shiftable P_{SHIFT}), PV source generation (P_{PV}), energy storage operation

(P_{RESS}), and power exchange with the grid (P_{EX}) were recorded. The value of the objective function (9) was determined based on the recorded value of power exchanged with the grid (P_{EX}) and the hourly electricity prices shown in Figure 4. Simulations were carried out separately for the two days analyzed, each time starting from the battery SoC resulting from the measurements.




Figure 6. PV generation, total load, RESS operation, and power exchange with the grid on 21 September 2023, transformed to hourly resolution.






Figure 7. Building's power supply system model applied in simulations.

4. Simulation Results and Discussion

Two variants of the simulation were carried out to test the proposed optimization algorithm for each of the days analyzed. In the first variant, only the daily operation of the RESS was optimized, while in the second variant, both the operation of the RESS and the switching time of the SLs were optimized. Figure 8 shows the daily operating profiles of the RESS determined using the PSO algorithm, while Figure 9 shows the SoC of the storage. For comparison, the measured values of these quantities, resulting from the RESS control based on a factory-implemented rule-based algorithm, are also shown. Figure 10, on the other hand, shows the total load in the building, both measured and after optimizing the switching time of the SLs.




(a)




(b)

Figure 8. The measured and optimized daily operating profiles of the RESS (a) on 20 September 2023 and (b) on 21 September 2023.



(a)



(b)

Figure 9. RESS SoC resulting from the measured and optimized operating profiles of the RESS (a) on 20 September 2023 and (b) on 21 September 2023.




Figure 10. The measured and optimized total load of the residential building (a) on 20 September 2023 and (b) on 21 September 2023.

On 20 September (a day with negative energy prices), from midnight to 9 a.m., the RESS operation determined by the optimization algorithm (in both variants) was the same as the RESS operation recorded at that time (Figure 8a). Also, in the evening and the first part of the following night, the optimization results coincided with the measurements. The major differences in storage operation occurred between 9 a.m. and 3 p.m., i.e., during the period when energy prices were low. From 9 a.m. to 12 p.m., the RESS charging power calculated by the PSO algorithm was lower than the charging power resulting from the measurements. Controlling the storage in this way allowed it to operate in charging mode for a longer time compared to the situation when the storage was controlled by a rule-based algorithm (Figure 9a). As a result, the operation of the RESS was better adapted to the generation profile of the PV source.


On the second analyzed day, 21 September, differences in the RESS operating profile determined by the PSO algorithm and the measured profile were already noticeable at night (Figure 8b). During this period, the PSO algorithm controlled the RESS to operate in the discharge mode with a higher power than the power determined by the rule-based algorithm. Part of the discharged energy was used to cover the building's demand, while the remaining part was supplied to the grid. This was beneficial for both the power system and the prosumer. Discharging the RESS with a higher power at night reduces the power generated from non-renewable resources. At the same time, the RESS became better prepared to operate in charging mode during the day (Figure 9b), when energy was generated by the PV source, which was noticeable around noon. On both the days analyzed, the effect of shifting load from evening to late morning hours on the operation of the RESS was also evident. During the hours when the demand in the building had increased (Figure 10), the RESS was charged with lower power, and the capacity saved in this way was utilized at other times.

A measurable effect of optimizing the RESS and the SL was to increase the self-consumption of energy produced by the PV source compared to the situation when the


storage was controlled by a rule-based algorithm. This is shown in Figure 11. After the application of the PSO, on the first analyzed day (Figure 11a), the self-consumption admittedly decreased from 9 a.m. to 12 p.m., but it was higher in the remaining hours in relation to the measurements. As a result, the total daily self-consumption increased from 43.1% to 46.9% after optimizing the RESS operation (Table 2). On the other hand, after optimizing the RESS and SL, the daily self-consumption increased to 48.0%. An even greater increase in self-consumption was recorded on 21 September (Figure 11b). On that day, the daily self-consumption increased from 36.7% when controlling the RESS with a rule-based algorithm to 41.8% after applying PSO. There was a further increase to 48.5% after optimizing storage and shiftable load.

Table 2. The daily performance of the analyzed residential building’s power supply system, both measured and resulting from the application of PSO.

Results Obtained with:	PV Generation	Load	RESS Operation		Grid Exchange		Self-Consumption	Objective Function
	kWh	kWh	Charge	Discharge	Import	Export	%	PLN
20 September 2023								
Measurements	26.0	9.3	14.8	5.1	0.6	7.6	43.1	−0.65
RESS optimization	26.0	9.3	15.7	5.6	0.0	6.6	46.9	0.00
RESS & SL optimization	26.0	9.3	15.7	4.6	0.0	5.6	48.0	0.00
21 September 2023								
Measurements	22.5	9.1	7.2	5.1	0.6	11.8	36.7	−5.12
RESS optimization	22.5	9.1	12.2	6.8	0.0	7.9	41.8	−3.84
RESS & SL optimization	22.5	9.1	14.5	9.0	0.0	7.8	48.5	−3.64



(a)



(b)

Figure 11. Self-consumption of PV energy resulting from the measured and optimized operating profiles of the RESS and SL (a) on 20 September 2023 and (b) on 21 September 2023.

A change in the level of self-consumption affects the exchange of energy with the LV distribution network. This is illustrated in Figure 12. After the application of PSO, only the export of energy to the grid occurred. On 20 September (Figure 12a), energy exports occurred for five hours, from 9 a.m. to 2 p.m., with a clear trend of reduction during hours when PV generation was higher. This phenomenon was closely related to the level of energy prices during these hours. From 9 a.m. to 10 a.m. and from 1 p.m. to 2 p.m., energy prices were at their highest and amounted to 0.01 PLN/kWh. From 10 a.m. to 11 a.m. and from 12 p.m. to 1 p.m., the prices dropped to -0.01 PLN/kWh, and from 11 a.m. to 12 p.m., the price was -0.02 PLN/kWh. Thus, to reduce the costs incurred by the prosumer as a result of the energy exports during hours when prices were negative, the PSO algorithm adequately reduced the exchange with the grid. This means that, when using an optimization-based EMS, energy prices can be an appropriate tool to influence the operating profiles of the RESS and the SL and, thus, the value of power exchanged with the grid. After optimizing the RESS operating profile, on 20 September, the daily energy export to the grid decreased from 7.6 kWh to 6.6 kWh (Table 2). The use of DSM further reduced it by 1 kWh. An even more pronounced reduction in the amount of energy exported to the grid as a result of PSO application was recorded on 21 September (Figure 12b). On that day, export to the grid decreased from 11.8 kWh to 7.9 kWh in the first optimization variant and to 7.8 kWh in the second variant.




Figure 12. Power exchange with the grid resulting from the measured and optimized operating profiles of the RESS and SL (a) on 20 September 2023 and (b) on 21 September 2023.

In the method applied to optimize the operation of RESS and SL, it was assumed that the objective function was to maximize the daily financial neutrality of the prosumer. This required minimizing both cost and income. The results of the calculations are shown in Figure 13 (positive values represent the cost for the prosumer, and negative values

represent their income). On 20 September (Figure 13a), the prosumer earned income or incurred a cost only from 9 a.m. to 2 p.m., as there is no exchange of energy with the grid during the remaining hours. However, since energy prices were close to zero at this time, the income generated and the costs incurred were negligible and offset each other. As a result, complete financial neutrality of the prosumer was achieved on that day. The situation was slightly different on the next analyzed day. On 21 September (Figure 13b), after applying the PSO, the prosumer did not incur any costs, since the import of energy from the grid was zero and the energy prices on that day were exclusively positive. Instead, the prosumer received income for the energy sold. However, after optimization, the total daily income was approximately 25% lower than in the case when the RESS was controlled by a rule-based algorithm. Thus, the financial neutrality of the prosumer also increased on that day. A summary of the analysis results for both days is shown in Table 2. Detailed results are given in Appendix A (Tables A1–A6).




Figure 13. The prosumer’s cost (positive values) and income (negative values) calculated based on measured and optimized power exchange with the grid (a) on 20 September 2023 and (b) on 21 September 2023.

When carrying out the simulations described above, a series of experiments were performed to observe the convergence process of the PSO algorithm. Figure 14 shows the results of the subsequent 10 daily PSO-optimized operating profiles of the RESS on 20 September 2023 (the daily operating profiles of the RESS shown in Figure 8 are the average of the 10 PSO optimizations). Additionally, the convergence curves of the PSO algorithm executions for the corresponding RESS optimization results displayed in Figure 14 are shown in Figure 15. The curves show decreasing values of the objective function for the swarm leader of each PSO run in successive iterations. A swarm of 40 particles was used for

these experiments. The PSO algorithm's parameter values χ and c_1, c_2 were experimentally selected and set to $\chi = 0.73$ and $c_1 = c_2 = 2.25$. The average duration of a single PSO optimization, obtained from 30 test runs, was approximately 22 s, with the maximum number of iterations set at 320. All simulations were carried out on a computer with an Intel Core i7-3770K CPU, 3.5 GHz with 16 GB of RAM, running on a 64-bit Windows 10 operating system.




Figure 14. Results of the subsequent 10 PSO-based optimizations of the RESS operating profiles on 20 September 2023.




Figure 15. Convergence curves for 10 consecutive runs of the PSO algorithm obtained for the RESS optimization variant.

5. Home Energy Management System Architecture

An EMS designed to improve the energy management of residential buildings by controlling and scheduling the use of household equipment is called a home energy management system (HEMS) [38]. Figure 16 shows the HEMS architecture applying the proposed PSO-based method to optimize the operating profiles of the RESS and the SLs. This is a typical HEMS architecture [39], containing various household appliances, a PV source, an RESS, an electric vehicle, and a central controller. Household appliances are divided into conventional appliances, which require a smart plug, and smart appliances. The central controller is the core component of HEMS, and it optimizes and controls the energy usage in the household. Wired and wireless systems are used for communication between the corresponding devices. A human-machine interface (HMI) displays information from the controller, smart meters, sensors, smart plugs, and the smart appliances of the HEMS.




Figure 16. The HEMS architecture applying the proposed PSO-based method to optimize the operating profiles of the RESS and SLs.

The HEMS shown in Figure 16 is in the implementation stage in the residential building where the measurements used in this article were taken. A second analogous HEMS is being implemented in a similar building, also equipped with a PV source, RESS, and SLs. The designed HEMS will operate according to the following principles. At the planning stage, the central controller will collect information on the day-ahead energy prices, the PV source generation forecast, the building's baseline demand forecast, and the storage's SoC. The PV generation forecast will be based on numerical weather forecasts [40]. The building's baseline demand forecast will be determined using historical load profiles [41]. Using the HMI, the user will enter information into the system about the time intervals in which SLs can be switched on. The planned operating programs of these appliances will also be provided, and HEMS will download appropriate load profiles from the database containing data analogous to the load profiles described in [42]. Based on the described input data, the PSO algorithm implemented in the central controller will determine the RESS operating profile and the times of switching on the SLs. The proposed HEMS will use a moving horizon of 24 h. The operating schedule will be updated in accordance with the update time of numerical weather forecasts. During the implementation of the developed plan, data from energy meters will be recorded. In this way, the results of the applied forecasting and optimization methods will be verified and improved.

The practical implementation of HEMS in a real environment such as a residential building requires meeting several challenges, both technical and non-technical in nature. The first issue that determines the quality of the decisions developed by the HEMS is to ensure the highest possible accuracy of generation and load forecasts in the building. Other technical challenges include the need to equip many electrical devices with monitoring and control systems and to build a reliable communication system, which must also ensure a correspondingly high level of cybersecurity. An additional problem may be the need to integrate devices from different manufacturers, operating according to different communication standards or having no communication system at all, which directly affects the cost of system implementation. In turn, a non-technical challenge is the need to

raise awareness of people in the field of energy use and conservation so that residents of buildings equipped with HEMS will more willingly accept a situation in which some decisions are not made by them but by an automatic control system. It is obvious that the acceptance of such a situation will be easier for the residents when the decisions made by the HEMS system do not reduce their living comfort. This is another challenge that should be considered at the HEMS design and implementation stage.

6. Conclusions

The application of PV micro-installations to cover the electric energy needs of residential buildings is becoming increasingly popular worldwide. Unfortunately, the discrepancy between generation and load profiles results in low self-consumption, which means that a large part of the generated energy is transmitted to the LV grid, negatively affecting its operation. The remedy for this problem may be the use of RESSs and the implementation of DSM schemes, which involves switching on SLs at the appropriate time. However, such an extensive power supply system for a building requires a properly designed HEMS.

In this study, a PSO-based method was proposed to optimize the operation of an RESS and the switching time of SLs. The objective was to maximize the prosumer's financial neutrality, which was calculated based on dynamic energy prices. The proposed optimization method was validated using measurement results taken in a building equipped with an RESS controlled by a rule-based algorithm. Compared to the situation when the RESS was controlled by the rule-based algorithm, the simulation results demonstrated an increase in the self-consumption of produced energy. After the application of PSO, the total daily self-consumption increased from 43.1% to 46.9% on the first analyzed day and from 36.7% to 41.8% on the second day. An even greater increase was recorded after optimizing the RESS and SLs. In this case, the self-consumption increased to 48.0% on the first day and to 48.5% on the second day.

The increase in self-consumption affects the exchange of energy with the LV distribution grid. After optimizing the RESS operating profile, on the first analyzed day, the daily energy export to the grid decreased from 7.6 kWh to 6.6 kWh (13%), while on the second day it decreased from 11.8 kWh to 7.9 kWh (33%). The use of DSM further reduced the daily energy export to the grid. In addition, the proposed PSO-based algorithm also optimized the amount of energy exported to the grid at specific hours of the day, reducing exports at a time when PV generation was at its highest. This was particularly noticeable on the day with negative energy prices that occurred as a result of excess energy from renewable sources across the power system. This means that, using the proposed PSO-based HEMS, it is possible to use price signals from the wholesale energy market to control the operation of the individual RESS and the SLs in a way that improves the LV network operating conditions. Therefore, the proposed algorithm not only benefits the prosumer by maximizing self-consumption, but it also decreases the investment pressure on the distribution system operator by minimizing the negative grid impact of the prosumer's PV micro-installations. The proposed architecture of the HEMS is generic and practically applicable to any residential building, so it can be widely implemented in such locations.

Further research will include the integration of other renewable energy sources (e.g., wind microturbines) and electric appliances used to ensure thermal comfort in the building (heat pump, air conditioning, heat storage) into the HEMS system. The effects of controlling the prosumer power supply system according to other objective functions (e.g., cost minimization) will also be analyzed, and the impact of different control strategies on the operation of the low-voltage distribution network will be compared.

Author Contributions: Conceptualization, R.K.; methodology, R.K., M.P. and T.N.; validation, R.K., M.P. and T.N.; formal analysis, R.K., M.P. and T.N.; investigation, R.K., M.P. and T.N.; resources, R.K., M.P. and T.N.; data curation, R.K., M.P. and T.N.; writing—original draft preparation, R.K. and M.P.; writing—review and editing, R.K., M.P. and T.N.; visualization, M.P. and R.K.; PSO-based optimization algorithm design and implementation, M.P.; supervision, R.K. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Data Availability Statement: The original contributions presented in the study are included in the article, further inquiries can be directed to the corresponding author.

Conflicts of Interest: The authors report no conflicts of interest.

Abbreviations

The following abbreviations are used in this manuscript:

DP	Dynamic Programming
DSM	Demand-Side Management
EMS	Energy Management System
HEMS	Home Energy Management System
MILP	Mixed-Integer Linear Programming
OPF	Optimal Power Flow
PSO	Particle Swarm Optimization
PV	Photovoltaic
RESS	Residential Energy Storage System
UC	Unit Commitment
SoC	State of Charge
LV	Low Voltage
SL	Shiftable Load
HMI	Human–Machine Interface

Appendix A

Here we present detailed results of the daily performance of the analyzed residential building’s power supply system, both measured and resulting from the application of PSO. A positive value of grid exchange indicates import energy from the grid, while negative value indicates export energy to the grid. A positive value of RESS power indicates discharging, and a negative value indicates charging of the battery.

Table A1. The daily performance of the analyzed residential building’s power supply system on 20 September 2023—measurements.

Hour	Price	PV Generation	Load	RESS Operation	SoC	Grid Exchange	Self- Consumption	Objective Function
	PLN/kWh	Wh	Wh	Wh	%	Wh	%	PLN/h
0	0.4431	0	174	144	45	30	0	0.0131
1	0.4246	0	225	194	44	31	0	0.0131
2	0.4241	0	179	149	43	29	0	0.0124
3	0.4415	0	190	164	42	26	0	0.0116
4	0.4489	12	469	459	41	−2	100	−0.0010
5	0.3633	100	249	116	38	33	100	0.0120
6	0.4118	184	308	93	38	30	100	0.0125
7	0.4431	219	237	−16	37	34	100	0.0151
8	0.3098	2541	342	−2222	37	22	100	0.0067
9	0.0100	3564	301	−3297	46	34	100	0.0003
10	−0.0141	4080	292	−3817	60	29	100	−0.0004
11	−0.0252	4239	334	−3939	77	33	100	−0.0008
12	−0.0141	4012	453	−1324	93	−2237	44	0.0316
13	0.0100	3609	616	−82	100	−2911	19	−0.0291
14	0.2927	2404	327	−87	100	−1990	17	−0.5825
15	0.7134	959	518	5	99	−446	53	−0.3180
16	0.7437	63	309	210	99	36	100	0.0266
17	0.8262	0	1534	1500	98	31	0	0.0258
18	0.7415	0	547	517	90	30	0	0.0219
19	0.7000	0	478	452	87	26	0	0.0182
20	0.3737	0	416	387	85	29	0	0.0108
21	0.4456	0	266	228	83	37	0	0.0167
22	0.4443	0	314	273	81	40	0	0.0179
23	0.4484	0	245	211	80	33	0	0.0150

Table A2. The daily performance of the analyzed residential building’s power supply system on 20 September 2023—RESS optimization.

Hour	Price	PV Generation	Load	RESS Operation	SoC	Grid Exchange	Self-Consumption	Objective Function
	PLN/kWh	Wh	Wh	Wh	%	Wh	%	PLN/h
0	0.4431	0	174	175	45	−1	0	−0.0005
1	0.4246	0	225	227	44	−2	0	−0.0008
2	0.4241	0	179	181	43	−2	0	−0.0008
3	0.4415	0	190	192	42	−1	0	−0.0006
4	0.4489	12	469	459	41	−1	100	−0.0006
5	0.3633	100	249	151	38	−2	100	−0.0008
6	0.4118	184	308	125	37	−1	100	−0.0005
7	0.4431	218	237	20	36	−2	100	−0.0007
8	0.3098	2542	342	−2197	36	−3	100	−0.0008
9	0.0100	3564	301	−1121	45	−2141	40	−0.0214
10	−0.0141	4080	292	−2784	50	−1004	75	0.0141
11	−0.0252	4239	334	−3570	62	−335	92	0.0085
12	−0.0141	4013	453	−2486	77	−1073	73	0.0152
13	0.0100	3609	616	−1009	87	−1985	45	−0.0198
14	0.2927	2404	327	−2074	91	−3	100	−0.0009
15	0.7134	959	518	−441	100	0	100	0.0001
16	0.7437	63	309	246	100	0	100	0.0000
17	0.8262	0	1534	1534	99	0	0	0.0000
18	0.7415	0	547	547	90	0	0	−0.0001
19	0.7000	0	478	478	87	0	0	0.0000
20	0.3737	0	416	416	84	0	0	0.0000
21	0.4456	0	266	266	82	0	0	0.0001
22	0.4443	0	314	314	80	0	0	0.0000
23	0.4484	0	245	244	78	0	0	0.0001

Table A3. The daily performance of the analyzed residential building’s power supply system on 20 September 2023—RESS & SL optimization.

Hour	Price	PV Generation	Base Load	Shifted Load	Total Load	RESS Operation	SoC	Grid Exchange	Self-Consumption	Objective Function
	PLN/kWh	Wh	Wh	Wh	Wh	Wh	%	Wh	%	PLN/h
0	0.4431	0	174	0	174	175	45	−1	0	−0.0006
1	0.4246	0	225	0	225	227	44	−2	0	−0.0008
2	0.4241	0	179	0	179	180	43	−1	0	−0.0006
3	0.4415	0	190	0	190	192	42	−1	0	−0.0006
4	0.4489	12	469	0	469	458	41	−1	100	−0.0005
5	0.3633	100	249	0	249	151	38	−2	100	−0.0006
6	0.4118	184	308	0	308	125	37	−1	100	−0.0006
7	0.4431	218	237	0	237	20	36	−1	100	−0.0004
8	0.3098	2542	342	0	342	−2198	36	−1	100	−0.0005
9	0.0100	3564	301	0	301	−1480	45	−1782	50	−0.0178
10	−0.0141	4080	292	0	292	−2922	52	−866	79	0.0122
11	−0.0252	4239	334	1000	1334	−2638	64	−267	94	0.0067
12	−0.0141	4013	453	0	453	−2706	75	−854	79	0.0121
13	0.0100	3609	616	0	616	−1221	86	−1772	51	−0.0177
14	0.2927	2404	327	0	327	−2075	91	−2	100	−0.0006
15	0.7134	959	518	0	518	−441	100	0	100	0.0001
16	0.7437	63	309	0	309	246	100	0	100	−0.0001
17	0.8262	0	534	0	534	534	99	0	0	0.0000
18	0.7415	0	547	0	547	546	96	0	0	0.0001
19	0.7000	0	478	0	478	478	92	0	0	−0.0001
20	0.3737	0	416	0	416	416	90	0	0	0.0001
21	0.4456	0	266	0	266	266	87	0	0	0.0000
22	0.4443	0	314	0	314	313	86	0	0	0.0000
23	0.4484	0	245	0	245	245	84	0	0	−0.0001

Table A4. The daily performance of the analyzed residential building’s power supply system on 21 September 2023—measurements.

Hour	Price	PV Generation	Load	RESS Operation	SoC	Grid Exchange	Self- Consumption	Objective Function
	PLN/kWh	Wh	Wh	Wh	%	Wh	%	PLN/h
0	0.4487	0	244	212	78	33	0	0.0147
1	0.4487	0	197	167	77	30	0	0.0135
2	0.4487	0	170	139	76	31	0	0.0141
3	0.4487	0	241	208	76	34	0	0.0151
4	0.4983	6	316	275	74	34	100	0.0171
5	0.4846	93	301	174	72	34	100	0.0165
6	0.4846	171	243	42	72	29	100	0.0141
7	0.4846	207	263	24	71	32	100	0.0154
8	0.4535	2451	335	−2148	71	31	100	0.0142
9	0.4272	3518	257	−3287	80	25	100	0.0108
10	0.4267	3938	352	−1466	93	−2120	46	−0.9047
11	0.4272	4072	279	−83	100	−3711	9	−1.5854
12	0.4443	3559	447	−87	100	−3024	15	−1.3436
13	0.4516	2380	600	−74	99	−1705	28	−0.7701
14	0.6471	1313	342	−84	99	−887	32	−0.5738
15	0.6836	725	402	42	99	−365	50	−0.2498
16	0.7388	49	1271	1161	98	60	100	0.0440
17	0.7438	0	810	780	93	32	0	0.0241
18	0.6471	0	412	383	89	29	0	0.0188
19	0.6385	0	453	426	87	27	0	0.0173
20	0.4645	0	369	343	84	26	0	0.0119
21	0.4458	0	288	254	82	34	0	0.0153
22	0.4349	0	322	291	81	31	0	0.0135
23	0.4354	0	229	197	79	33	0	0.0143

Table A5. The daily performance of the analyzed residential building’s power supply system on 21 September 2023—RESS optimization.

Hour	Price	PV Generation	Load	RESS Operation	SoC	Grid Exchange	Self- Consumption	Objective Function
	PLN/kWh	Wh	Wh	Wh	%	Wh	%	PLN/h
0	0.4487	0	245	408	78	−164	0	−0.0734
1	0.4487	0	198	367	76	−170	0	−0.0761
2	0.4487	0	170	343	74	−172	0	−0.0774
3	0.4487	0	241	406	72	−165	0	−0.0740
4	0.4983	6	316	443	69	−133	100	−0.0661
5	0.4846	93	301	351	67	−143	100	−0.0694
6	0.4846	171	243	216	65	−144	100	−0.0700
7	0.4846	207	263	196	64	−140	100	−0.0680
8	0.4535	2451	335	−1998	62	−118	95	−0.0536
9	0.4272	3518	257	−3125	71	−136	96	−0.0581
10	0.4267	3938	352	−3445	84	−141	96	−0.0601
11	0.4272	4071	279	−3658	98	−135	97	−0.0576
12	0.4443	3559	447	−2	100	−3110	13	−1.3817
13	0.4516	2380	600	−2	100	−1778	25	−0.8029
14	0.6471	1313	342	−2	100	−969	26	−0.6271
15	0.6836	725	402	−2	100	−322	56	−0.2201
16	0.7388	49	1271	1221	100	1	100	0.0006
17	0.7438	0	810	811	93	−1	0	−0.0004
18	0.6471	0	412	413	88	−1	0	−0.0006
19	0.6385	0	453	451	86	2	0	0.0013
20	0.4645	0	369	370	84	0	0	0.0000
21	0.4458	0	288	288	81	0	0	0.0000
22	0.4349	0	322	324	80	−2	0	−0.0007
23	0.4354	0	230	230	78	−1	0	−0.0004

Table A6. The daily performance of the analyzed residential building’s power supply system on 21 September 2023—RESS & SL optimization.

Hour	Price	PV Generation	Base Load	Shifted Load	Total Load	RESS Operation	SoC	Grid Exchange	Self-Consumption	Objective Function
	PLN/kWh	Wh	Wh	Wh	Wh	Wh	%	Wh	%	PLN/h
0	0.4487	0	244	0	244	857	78	−612	0	−0.2746
1	0.4487	0	197	0	197	806	73	−609	0	−0.2732
2	0.4487	0	170	0	170	800	69	−630	0	−0.2825
3	0.4487	0	241	0	241	854	64	−613	0	−0.2751
4	0.4983	6	316	0	316	831	59	−520	100	−0.2592
5	0.4846	93	301	0	301	742	54	−534	100	−0.2586
6	0.4846	171	243	0	243	609	50	−538	100	−0.2605
7	0.4846	207	263	0	263	606	47	−550	100	−0.2666
8	0.4535	2451	335	0	335	−1674	43	−442	82	−0.2004
9	0.4272	3518	257	0	257	−2741	50	−520	85	−0.2222
10	0.4267	3938	352	800	1152	−2272	62	−513	87	−0.2190
11	0.4272	4071	279	400	679	−2888	71	−505	88	−0.2157
12	0.4443	3559	447	0	447	−2640	83	−471	87	−0.2095
13	0.4516	2380	600	0	600	−1325	94	−455	81	−0.2054
14	0.6471	1313	342	0	342	−971	100	1	100	0.0005
15	0.6836	725	402	0	402	−2	100	−322	56	−0.2200
16	0.7388	49	471	0	471	425	100	−3	100	−0.0023
17	0.7438	0	410	0	410	412	98	−2	0	−0.0015
18	0.6471	0	412	0	412	409	95	3	0	0.0022
19	0.6385	0	453	0	453	458	93	−4	0	−0.0026
20	0.4645	0	369	0	369	371	90	−1	0	−0.0007
21	0.4458	0	288	0	288	285	88	3	0	0.0014
22	0.4349	0	322	0	322	317	87	5	0	0.0020
23	0.4354	0	229	0	229	218	85	11	0	0.0048

References

1. International Energy Agency. Renewable Energy Market Update. Outlook for 2023 and 2024. Available online: https://iea.blob.core.windows.net/assets/63c14514-6833-4cd8-ac53-f9918c2e4cd9/RenewableEnergyMarketUpdate_June2023.pdf (accessed on 11 September 2024).
2. Solar Power Europe. Global Market Outlook for Solar Power 2023–2027. Available online: <https://www.solarpowereurope.org/insights/outlooks/eu-market-outlook-for-solar-power-2023-2027/detail> (accessed on 11 September 2024).
3. International Energy Agency. Snapshot of Global PV Markets 2023. Available online: https://iea-pvps.org/wp-content/uploads/2023/04/IEA_PVPS_Snapshot_2023.pdf (accessed on 3 September 2024).
4. Polish Power Transmission and Distribution Association. Micro-Installations in Poland as of 30 September 2023. Available online: <http://ptpiree.pl/energetyka-w-polsce/energetyka-w-liczbach/mikroinstalacje-w-polsce> (accessed on 7 September 2024).
5. Żuk, P.; Żuk, P. Prosumers in Action: The Analysis of Social Determinants of Photovoltaic Development and Prosumer Strategies in Poland. *Int. J. Energy Econ. Policy* **2022**, *12*, 294–306. [CrossRef]
6. European Environment Agency. Energy Prosumers in Europe—Citizen Participation in the Energy Transition. Technical Report No 1/2022, EEA. 2022. Available online: <https://www.eea.europa.eu/publications/the-role-of-prosumers-of> (accessed on 6 September 2024).
7. Kurz, D.; Nowak, A. Analysis of the Impact of the Level of Self-Consumption of Electricity from a Prosumer Photovoltaic Installation on Its Profitability Under Different Energy Billing Scenarios in Poland. *Energies* **2023**, *16*, 946. [CrossRef]
8. Bolson, N.; Prieto, P.; Patzek, T. Capacity Factors for Electrical Power Generation from Renewable and Nonrenewable Sources. *Proc. Natl. Acad. Sci. USA* **2022**, *119*, e2205429119. [CrossRef] [PubMed]
9. Olczak, P. Comparison of Modeled and Measured Photovoltaic Microinstallation Energy Productivity. *Renew. Energy Focus* **2022**, *43*, 246–254. [CrossRef]
10. Eurostat. Electricity and Heat Statistics. Consumption of Electricity per Capita in the Households Sector. Available online: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Electricity_and_heat_statistics (accessed on 11 September 2024).
11. Azarova, V.; Cohen, J.J.; Kollmann, A.; Reichl, J. Reducing Household Electricity Consumption during Evening Peak Demand Times: Evidence from a Field Experiment. *Energy Policy* **2020**, *144*, 111657. [CrossRef]
12. Hummel, S.; Betzold, C.; Dentel, A. Impact of the Weather Forecast Quality on a MPC-driven Heat Pump Heating System. In Proceedings of the CLIMA 2022 Conference, Rotterdam, The Netherlands, 22–25 May 2022. [CrossRef]
13. Uzum, B.; Onen, A.; Hasanien, H.M.; Mueen, S.M. Rooftop Solar PV Penetration Impacts on Distribution Network and Further Growth Factors—A Comprehensive Review. *Electronics* **2021**, *10*, 55. [CrossRef]

14. Sharma, V.; Haque, M.H.; Aziz, S.M.; Kauschke, T. Smart Inverter and Battery Storage Controls to Reduce Financial Loss Due to Overvoltage-Induced PV Curtailment in Distribution Feeders. *Sustain. Energy Grids Netw.* **2023**, *34*, 101030. [\[CrossRef\]](#)
15. Sharma, V.; Haque, M.H.; Aziz, S.M.; Kauschke, T. Reduction of PV Curtailment through Optimally Sized Residential Battery Storage. In Proceedings of the 2020 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES), Jaipur, India, Jaipur, India, 16–19 December 2020; pp. 1–6. [\[CrossRef\]](#)
16. Kandari, R.; Neeraj, N.; Micallef, A. Review on Recent Strategies for Integrating Energy Storage Systems in Microgrids. *Energies* **2023**, *16*, 317. [\[CrossRef\]](#)
17. Korab, R.; Połomski, M.; Smółka, M. Evaluating the Risk of Exceeding the Normal Operating Conditions of a Low-Voltage Distribution Network Due to Photovoltaic Generation. *Energies* **2022**, *15*, 1969. [\[CrossRef\]](#)
18. Bakare, M.S.; Abdulkarim, A.; Zeeshan, M.; Shuaibu, A.N. A Comprehensive Overview on Demand Side Energy Management towards Smart Grids: Challenges, Solutions, and Future Direction. *Energy Inform.* **2023**, *6*, 4. [\[CrossRef\]](#)
19. Restrepo, M.; Cañizares, C.A.; Simpson-Porco, J.W.; Su, P.; Taruc, J. Optimization- and Rule-based Energy Management Systems at the Canadian Renewable Energy Laboratory Microgrid Facility. *Appl. Energy* **2021**, *290*, 116760. [\[CrossRef\]](#)
20. Kanwar, A.; Rodríguez, D.I.H.; von Appen, J.; Braun, M. A Comparative Study of Optimization- and Rule-Based Control for Microgrid Operation. In Proceedings of the Power and Energy Student Summit (PESS) 2015, Dortmund, Germany, 13–14 January 2015. [\[CrossRef\]](#)
21. Olivares, D.E.; Cañizares, C.A.; Kazerani, M. A Centralized Energy Management System for Isolated Microgrids. *IEEE Trans. Smart Grid* **2014**, *5*, 1864–1875. [\[CrossRef\]](#)
22. Salpakari, J.; Lund, P. Optimal and Rule-Based Control Strategies for Energy Flexibility in Buildings with PV. *Appl. Energy* **2016**, *161*, 425–436. [\[CrossRef\]](#)
23. Varzaneh, S.G.; Raziabadi, A.; Hosseinzadeh, M.; Sanjari, M.J. Optimal Energy Management for PV-integrated Residential Systems Including Energy Storage System. *IET Renew. Power Gener.* **2021**, *15*, 17–29. [\[CrossRef\]](#)
24. Gelleschus, R.; Böttiger, M.; Bocklisch, T. Optimization-Based Control Concept with Feed-in and Demand Peak Shaving for a PV Battery Heat Pump Heat Storage System. *Energies* **2019**, *12*, 2098. [\[CrossRef\]](#)
25. Ali, A.O.; Hamed, A.M.; Abdelsalam, M.M.; Sabry, M.N.; Elmarghany, M.R. Energy Management of Photovoltaic-Battery System Connected with the Grid. *J. Energy Storage* **2022**, *55*, 105865. [\[CrossRef\]](#)
26. Mahmood, D.; Latif, S.; Anwar, A.; Hussain, S.J.; Jhanjhi, N.Z.; Sama, N.U.; Humayun, M. Utilization of ICT and AI Techniques in Harnessing Residential Energy Consumption for an Energy-Aware Smart City: A Review. *Int. J. Adv. Appl. Sci.* **2021**, *8*, 50–66. [\[CrossRef\]](#)
27. Rojek, I.; Mikołajewski, D.; Mroziński, A.; Macko, M. Machine Learning- and Artificial Intelligence-Derived Prediction for Home Smart Energy Systems with PV Installation and Battery Energy Storage. *Energies* **2023**, *16*, 6613. [\[CrossRef\]](#)
28. Zulu, M.L.T.; Carpanen, R.P.; Tiako, R. A Comprehensive Review: Study of Artificial Intelligence Optimization Technique Applications in a Hybrid Microgrid at Times of Fault Outbreaks. *Energies* **2023**, *16*, 1786. [\[CrossRef\]](#)
29. Kennedy, J.; Eberhart, R. Particle Swarm Optimization. In Proceedings of the ICNN'95—International Conference on Neural Networks, Perth, WA, Australia, 27 November–1 December 1995; Volume 4, pp. 1942–1948. [\[CrossRef\]](#)
30. Gad, A.G. Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review. *Arch. Comput. Methods Eng.* **2022**, *29*, 2531–2561. [\[CrossRef\]](#)
31. Kennedy, J.; Eberhart, R.C.; Shi, Y. *Swarm Intelligence*; Morgan Kaufmann Publishers Inc.: San Francisco, CA, USA, 2001; pp. 328–331.
32. Clerc, M.; Kennedy, J. The Particle Swarm—Explosion, Stability, and Convergence in a Multidimensional Complex Space. *IEEE Trans. Evol. Comput.* **2002**, *6*, 58–73. [\[CrossRef\]](#)
33. Electric Power Research Institute. OpenDSS—Electric Power Distribution System Simulator. Available online: <https://www.epri.com/pages/sa/opendss> (accessed on 20 September 2024).
34. Official Journal of the European Union. Commission Regulation (EU) 2017/2195 of 23 November 2017 Establishing a Guideline on Electricity Balancing. Available online: <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32017R2195&from=LV> (accessed on 11 September 2024).
35. Nouicer, A.; Kehoe, A.M.; Nystén, J.; Fouquet, D.; Hancher, L.; Meeus, L. The EU Clean Energy Package (Ed. 2020). 2020. Available online: <https://fsr.eu.eu/publications/?handle=1814/68899> (accessed on 11 September 2024).
36. PSE S.A. Balancing Market Operation—Settlement Prices. Available online: <https://www.pse.pl/web/pse-eng/data/balancing-market-operation/settlement-prices> (accessed on 11 September 2024).
37. Maciejowska, K. Assessing the Impact of Renewable Energy Sources on the Electricity Price Level and Variability—A Quantile Regression Approach. *Energy Econ.* **2020**, *85*, 104532. [\[CrossRef\]](#)
38. Zafar, U.; Bayhan, S.; Sanfilippo, A. Home Energy Management System Concepts, Configurations, and Technologies for the Smart Grid. *IEEE Access* **2020**, *8*, 119271–119286. [\[CrossRef\]](#)
39. Han, B.; Zahraoui, Y.; Mubin, M.; Mekhilef, S.; Seyedmahmoudian, M.; Stojcevski, A. Home Energy Management Systems: A Review of the Concept, Architecture, and Scheduling Strategies. *IEEE Access* **2023**, *11*, 19999–20025. [\[CrossRef\]](#)
40. Korab, R.; Kandzia, T.; Naczyński, T. Short-Term Forecasting of Photovoltaic Power Generation. *Prz. Elektrotechniczny* **2023**, *97*, 31–37. [\[CrossRef\]](#)

41. Kychkin, A.V.; Chasparis, G.C. Feature and Model Selection for Day-Ahead Electricity-Load Forecasting in Residential Buildings. *Energy Build.* **2021**, *249*, 111200. [CrossRef]
42. Papadopoulos, T.; Barzegkar-Ntovom, G.; Kryonidis, G.; Doukas, D.; Marinopoulos, A.; Covrig, C.-F.; Kontis, E. High Resolution Profiles of Residential Appliances. IEEE Dataport. 18 February 2020. Available online: <https://ieee-dataport.org/open-access/high-resolution-profiles-residential-appliances> (accessed on 11 September 2024). [CrossRef]

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.