



POLITECHNIKA ŚLĄSKA
Wydział Inżynierii Środowiska i Energetyki
Katedra Maszyn i Urządzeń Energetycznych

Wspólna Szkoła Doktorska

PRACA DOKTORSKA

mgr inż. **Paweł Machał**

„Prognozowanie zapotrzebowania na energię elektryczną i gaz
w firmie TAURON Sprzedaż sp. z o.o. w horyzoncie krótkoterminowym”

Promotor: dr hab. inż. **Leszek Remiorz, prof. PS**

Opiekun pomocniczy: mgr inż. **Dariusz Bukowiec**

Dziedzina nauki:

nauki inżynierjno-techniczne

Dyscyplina naukowa:

Inżynieria Środowiska, Górnictwo i Energetyka

Gliwice 2024

Składam serdeczne podziękowania Panu dr. hab. inż. Leszkowi Remiorzowi, Profesorowi Politechniki Śląskiej, za niezwykle cenne wskazówki, cierpliwość i zaangażowanie w proces tworzenia niniejszej pracy. Jego głęboka wiedza i doświadczenie były nieocenione dla powodzenia tego przedsięwzięcia.

Serdecznie dziękuję również Panu

mgr. inż. Dariuszowi Bukowcowi

za cenne uwagi, wsparcie oraz za poświęcony czas.

Jego wsparcie w realizacji doktoratu było znaczące.

Dziękuję mojej rodzinie i przyjaciołom za to, że byli przy mnie i mnie wspierali.

Praca ta powstała w ramach Doktoratu Wdrożeniowego, finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego w Polsce.

SPIS TREŚCI

SPIS TREŚCI	3
STRESZCZENIE	5
WYKAZ WAŻNIEJSZYCH OZNACZEŃ I SYMBOLI	10
1 WSTĘP	13
1.1 UZASADNIENIE PODJĘCIA TEMATU	13
1.2 CEL BADAŃ I ZAKRES PRACY	17
2 AKTUALNY STAN WIEDZY	18
2.1 CHARAKTERYSTYKA FUNKCJONOWANIA HANDLU ENERGIĄ ELEKTRYCZNĄ I GAZEM ZIEMNYM W POLSCE	18
2.2 TECHNIKI PROGNOZOWANIA I ANALIZY DANYCH	21
2.3 PROGNOZOWANIE ZAPOTRZEBOWANIA ODBIORCÓW GAZU ZIEMNEGO	24
2.4 STOSOWANE METODY I MODELE	25
2.4.1 <i>Regresja liniowa</i>	26
2.4.2 <i>Modele uczenia maszynowego i sieci neuronowe</i>	27
2.4.3 <i>Metoda naiwna</i>	30
2.4.4 <i>Metoda dnia podobnego</i>	31
2.4.5 <i>Modele prognostyczne generacji fotowoltaicznej</i>	33
2.5 BUDOWA MODELU	35
2.6 DOBÓR ZMIENNYCH OBJAŚNIAJĄCYCH	36
2.7 METRYKI UŻYWANE DO OCENY MODELI	37
3 CZYNNIKI WPŁYWAJĄCE NA JAKOŚĆ PROGNOZ	39
3.1 ŹRÓDŁA FOTOWOLTAICZNE	39
3.2 PROSUMENCI – GENERACJA „ZA LICZNIKIEM”	41
3.3 PROMIENIOWANIE SŁONECZNE	43
3.4 POMPY CIEPŁA	44
3.5 SEZONOWOŚĆ	46
3.6 INNE CZYNNIKI WPŁYWAJĄCE NA ZMIENNOŚĆ ZAPOTRZEBOWANIA	52
3.7 AGREGACJA DANYCH ODBIORCÓW	53
3.8 AGREGACJA ZMIENNYCH OBJAŚNIAJĄCYCH	58
4 METODYKA GENERACJI PROFILU ZAPOTRZEBOWANIA BRUTTO	62
4.1 HISTORYCZNY PROFIL ZAPOTRZEBOWANIA BRUTTO	62
4.2 WSPÓŁCZYNNIK ZMIENNOŚCI	64
4.3 MODEL SIECI NEURONOWEJ	65
4.4 WYNIKI UCZENIA SIECI NEURONOWEJ	67
4.5 WYNIKI ALGORYTMU	76
5 PROGNOZY Z WYKORZYSTANIEM METODY BRUTTO	84
5.1 MIKROGENERACJA – WYNIKI PROGNOZ	84
5.2 ZAPOTRZEBOWANIE BRUTTO – WYNIKI PROGNOZ	91
5.3 SUMA SKŁADOWYCH – WYNIKI PROGNOZ	94
5.4 WYBÓR PROGNOZ METEOROLOGICZNYCH	98
5.5 ZMIENNOŚĆ DANYCH RZECZYWISTYCH ZAPOTRZEBOWANIA NA ENERGIĘ ELEKTRYCZNĄ	103
5.6 KOSZTY ODCHYLEŃ PROGNOZ	107

6	DODATKOWE ZASTOSOWANIA METODY BRUTTO	110
7	PODSUMOWANIE I WNIOSKI KOŃCOWE	111
8	KIERUNKI DALSZYCH BADAŃ	114
	BIBLIOGRAFIA.....	116
	ZAŁĄCZNIKI	130

STRESZCZENIE

Polska, będąc członkiem Unii Europejskiej, podlega europejskim regulacjom dotyczącym rynków energii, szczególnie w kontekście wzrostu udziału odnawialnych źródeł energii oraz funkcjonowania systemu handlu emisjami CO₂. Znajduje to swoje odbicie nie tylko w wielu krajowych regulacjach prawnych, ale również ma wpływ na metody i narzędzia analityczne, stosowane w tym obszarze.

Dysertacja koncentruje się na problematyce prognozowania zapotrzebowania na energię elektryczną i gaz ziemny w horyzoncie krótkoterminowym. Początkowa część pracy dotyczy aktualnego stanu wiedzy na temat prognozowania zapotrzebowania na energię elektryczną i gaz ziemny, z uwzględnieniem specyfiki polskiego rynku oraz stosowanych metod i modeli predykcyjnych. Prognozowanie w tym kontekście jest wielowymiarowym problemem, obejmującym zarówno aspekty techniczne, jak i ekonomiczne, które mają bezpośredni wpływ na handel oraz optymalne zarządzanie zasobami. Następnie omówiono szczegóły organizacji polskiego rynku energii elektrycznej, w tym mechanizmy handlu na rynku hurtowym, roli operatorów systemów przesyłowych oraz sprzedawców energii, a także kluczowe regulacje, wpływające na prognozowanie zapotrzebowania.

W dalszej części pracy omówiono funkcjonowanie rynku gazu ziemnego, w tym analogię do rynku energii elektrycznej w zakresie metod prognozowania zapotrzebowania. Wskazano także główne czynniki mające wpływ na nominalną zapotrzebowania na gaz ziemny.

Kolejno przedstawiono przegląd współczesnych metod prognozowania zapotrzebowania na energię elektryczną, od klasycznych modeli statystycznych, takich jak modele liniowe i autoregresyjne, po zaawansowane techniki machine learning, takie jak sieci neuronowe czy drzewa decyzyjne. Szczególną uwagę poświęcono metodom wykorzystywanym w prognozach krótkoterminowych, które są niezbędne do minimalizacji kosztów operacyjnych. Omówiono wyzwania związane z uwzględnianiem zmiennych meteorologicznych oraz sezonowości w prognozach.

Następnie skupiono się na metodzie agregacji danych, budowie modeli predykcyjnych oraz doborze zmiennych predykcyjnych, które stanowią fundament skutecznych prognoz. Agregacja danych odgrywa kluczową rolę w eliminacji szumu oraz poprawie jakości dostępnych informacji, co umożliwia lepsze zrozumienie zachowań związanych z konsumpcją energii. Z kolei budowa modeli predykcyjnych, opartych na takich metodach jak sieci neuronowe czy drzewa regresji, umożliwia wykorzystanie złożonych wzorców w danych historycznych, by lepiej przewidywać przyszłe zapotrzebowanie. Dobór odpowiednich zmiennych predykcyjnych, takich jak temperatura, nasłonecznienie czy godziny szczytu zużycia, pozwala na poprawę jakości prognoz, minimalizując błąd przewidywań. W dalszej części pracy omówiono aktualne trendy w energetyce, m.in. źródła fotowoltaiczne, pompy ciepła i inne czynniki wpływające na zapotrzebowanie. Przeanalizowano również wyzwania związane z agregacją danych odbiorców i zmiennych objaśniających oraz budowę modeli prognostycznych. Dokonano oceny wpływu tych czynników na dokładność prognoz,

a także przedstawiono metryki stosowane do oceny wydajności modeli. Następnie omówiono wyzwania związane z prognozowaniem zapotrzebowania na energię elektryczną oraz produkcji z mikrogeneracji PV, z uwzględnieniem dokładności prognoz meteorologicznych, doboru zmiennych predykcyjnych oraz wpływu błędów prognoz na koszty działalności spółki obrotu.

Prognozowanie zapotrzebowania na energię elektryczną staje się coraz bardziej skomplikowane, ze względu na rosnącą zmienność generacji pochodzącej z odnawialnych źródeł energii oraz dynamicznie zmieniające się warunki meteorologiczne. Dokładność prognozowania zapotrzebowania na energię oraz mikrogeneracji, w szczególności z instalacji fotowoltaicznych, stanowi kluczowy element w zarządzaniu współczesnymi systemami elektroenergetycznymi. Powyższy aspekt powoduje zmienność badanego szeregu czasowego (profilu zapotrzebowania netto), skorelowaną z natężeniem promieniowania słonecznego. Dlatego została podjęta próba odseparowania z zagregowanych danych o zapotrzebowaniu netto składowych zapotrzebowania brutto oraz generacji mikroinstalacji fotowoltaicznych. Następnie wyszczególnione przebiegi czasowe zostały poddane badaniu korelacji ze zmiennymi objaśniającymi.

Przedstawiono wyniki badań, zwracając szczególną uwagę na dokładność metod i modeli prognozowania, identyfikację kluczowych zmiennych, wpływających na zapotrzebowanie oraz skuteczność zastosowanych metod. Omówiono również wnioski wynikające z analizy wpływu zmiennych meteorologicznych na prognozowanie zapotrzebowania oraz produkcji energii z fotowoltaiki. Skupiono się na możliwych kierunkach doskonalenia obecnych modeli prognozowania. Zwrócono uwagę na obszary, w których należy skupić dalsze wysiłki badawcze, takie jak integracja dodatkowych danych meteorologicznych, lepsza adaptacja modeli do zmiennych warunków rynkowych, a także wprowadzenie bardziej zaawansowanych technik sztucznej inteligencji – głębokie sieci neuronowe czy metody hybrydowe, które mogą poprawić jakość prognoz w kontekście zmienności generacji OZE. W zakończeniu podkreślono aspekty nowości wprowadzone w ramach badań, takie jak poprawa efektywności prognoz krótkoterminowych, optymalizacja doboru zmiennych predykcyjnych oraz zastosowanie nowych metod agregacji danych, które mogą znaleźć praktyczne zastosowanie zarówno na poziomie operatorów systemu, jak i uczestników rynku energii.

W kontekście porównywania różnych modeli, ważnym aspektem jest ocena kosztów wynikających z niedokładności prognoz, które mogą prowadzić do destabilizacji systemu energetycznego oraz generować dodatkowe koszty operacyjne. Wprowadzenie odpowiednich zmiennych, takich jak zmienne meteorologiczne i dane historyczne, jest kluczowe dla uzyskania precyzyjnych prognoz. Zmienność generacji PV w krótkich okresach stanowi wyzwanie dla operatorów sieci, którzy muszą zbilansować system, opierając się na niepewnych prognozach natężenia promieniowania słonecznego. Analizie jakości poddano dostępne prognozy meteorologiczne, które są kluczowe dla dokładnego przewidywania zarówno zapotrzebowania na energię, jak i generacji z OZE. Niewielkie odchylenia w prognozach temperatury czy nasłonecznienia mogą prowadzić do znaczących błędów w prognozach energetycznych. Przedstawiono konsekwencje

ekonomiczne, wynikające z błędów prognozowania. Niedokładności prognoz mogą prowadzić do nieoptymalnego zarządzania zapasami energii, konieczności uruchamiania kosztownych rezerw mocy czy też kar nałożonych na spółki obrotu w postaci dodatkowego kosztu, za pobranie większej lub mniejszej ilości energii niż została zakontraktowana np. na giełdzie. Dokładne prognozowanie zapotrzebowania oraz generacji z OZE jest zatem nie tylko technicznym wyzwaniem, ale także kluczowym elementem w zarządzaniu kosztami i stabilnością systemu elektroenergetycznego.

Końcowa część pracy zawiera podsumowanie uzyskanych rezultatów oraz wynikające z tego kierunki dalszych prac w tej dziedzinie.

Abstract

Poland, as a member of the European Union, is subject to European regulations on energy markets, particularly regarding the increasing share of renewable energy sources and the functioning of the CO₂ emissions trading system. This is reflected not only in a series of national regulations but also impacts the analytical methods and tools used in this field.

The dissertation focuses on forecasting electricity and natural gas demand in the short term. The initial section addresses the current state of knowledge on forecasting electricity and natural gas demand, considering the specifics of the Polish market and the predictive methods and models used. Forecasting in this context is a multidimensional issue, encompassing both technical and economic aspects, which directly impact trading and optimal resource management. Details on the organization of the Polish electricity market follow, covering mechanisms in the wholesale market, the role of transmission system operators and energy suppliers, and key regulations affecting demand forecasting.

Subsequent parts discuss the functioning of the natural gas market, including its similarities to the electricity market regarding demand forecasting methods, and identify the main factors influencing natural gas demand. Next, a review of modern electricity demand forecasting methods is presented, ranging from classical statistical models, such as linear and autoregressive models, to advanced machine learning techniques, such as neural networks and decision trees. Special attention is given to methods used in short-term forecasts, essential for minimizing operational costs. Challenges related to incorporating meteorological variables and seasonality in forecasts are also discussed.

The focus then shifts to data aggregation, predictive model development, and predictor variable selection, which are fundamental to effective forecasts. Data aggregation plays a key role in noise reduction and improving information quality, facilitating a better understanding of energy consumption behaviors. The construction of predictive models, based on methods like neural networks or regression trees, allows for the use of complex patterns in historical data to better predict future demand. Selecting appropriate predictor variables, such as temperature, solar radiation, or peak usage hours, enhances forecast quality by minimizing prediction errors. The dissertation also explores current trends in energy, including photovoltaic sources, heat pumps, and other factors influencing demand. Additionally, challenges related to data aggregation for consumers and explanatory variables, as well as the development of predictive models, are analyzed. The impact of these factors on forecast accuracy is evaluated, and metrics used to assess model performance are presented.

Following this, challenges related to forecasting electricity demand and microgeneration from photovoltaics are discussed, with attention to the accuracy of meteorological forecasts, predictor variable selection, and the impact of forecast errors on trading company operational costs. Forecasting electricity demand is becoming increasingly complex due to the rising variability in renewable energy generation and dynamically changing meteorological conditions. Accurate forecasting of demand and

microgeneration, particularly from photovoltaic installations, is crucial for managing modern power systems. This aspect contributes to the variability of the studied time series (net demand profile) correlated with solar radiation intensity. Therefore, an attempt was made to separate, from aggregated net demand data, the components of gross demand and microgeneration from photovoltaic installations. These time series were then analyzed for correlations with explanatory variables.

The research results are presented, focusing on the accuracy of forecasting methods and models, identifying key variables influencing demand, and evaluating the effectiveness of the applied methods. Conclusions from analyzing the impact of meteorological variables on demand forecasting and photovoltaic energy production are also discussed. Potential directions for improving current forecasting models are considered, emphasizing areas for further research, such as integrating additional meteorological data, better adapting models to changing market conditions, and introducing more advanced AI techniques like deep neural networks or hybrid methods, which can enhance forecast quality in the context of renewable energy generation variability.

In conclusion, the new aspects introduced by this research, such as improved short-term forecast efficiency, optimal predictor variable selection, and the application of new data aggregation methods, are highlighted, indicating their practical applications at both the system operator level and for market participants.

In comparing different models, an important aspect is evaluating the costs resulting from forecast inaccuracies, which may lead to system instability and generate additional operational costs. Including variables such as meteorological variables and historical data is crucial for achieving precise forecasts. The variability in PV generation over short periods poses challenges for grid operators, who must balance the system based on uncertain solar radiation forecasts. The analysis also assesses available meteorological forecasts, which are key to accurately predicting both energy demand and renewable generation. Even small deviations in temperature or sunlight forecasts can lead to significant errors in energy forecasts. The economic consequences of forecasting errors are also presented. Forecast inaccuracies may lead to suboptimal energy stock management, the need for costly reserve capacity, or penalties imposed on trading companies for drawing energy than contracted, for example, on the exchange. Accurate demand and renewable generation forecasts are thus not only a technical challenge but also a key element in managing costs and power system stability.

The final part of the dissertation summarizes the obtained results and outlines directions for future work in this field.

WYKAZ WAŻNIEJSZYCH OZNACZEŃ I SYMBOLI

Ceny spot – notowanie na rynku dnia następnego (RDN), na którym ustalane są ceny dla energii dla każdej godziny doby. Notowania odbywają się w dniu poprzedzającym dzień dostawy.

Ceny RB – Cena energii niezbilansowania (CEN), wyznaczana przez OSP, zgodnie z zasadami określonymi w pkt. 13.3 WDB.

Harmonogram – okres obejmujący początek jako datę od oraz koniec jako datę do.

Dni robocze – dni robocze od poniedziałku do piątku, z wyłączeniem dni ustawowo określonych jako wolne.

Dane pomiarowe – dane pomiarowe w rozumieniu art. 3 pkt 61 ustawy Prawo energetyczne, tj. dane pozyskiwane lub wyznaczane dla punktu pomiarowego.

Dane pomiarowo-rozliczeniowe – dane wyznaczane na podstawie danych pomiarowych i odpowiednich algorytmów na potrzeby prowadzenia rozliczeń.

Grafik dobowo-godzinowy – zestawienie prognozowanego zużycia klienta w ramach trwania umowy. Prezentuje zużycie w każdej godzinie doby – dla wszystkich PPE objętych umową/ofertą.

PPE – punkt poboru energii elektrycznej (PPE) jest najmniejszą jednostką, dla której odbywa się zbilansowanie dostaw oraz dla której może nastąpić zmiana sprzedawcy.

PSE – polskie sieci elektroenergetyczne S.A. Operator systemu przesyłowego (OSP) elektroenergetycznego na obszarze Rzeczypospolitej Polskiej.

Redukcja mocy – (DSR) rozwiązanie polegające na dobrowolnym ograniczeniu poboru mocy czynnej przez klienta (Wykonawcę) w zamian za wynagrodzenie, którego wysokość jest określana w umowie o świadczenie usługi redukcji zapotrzebowania; produkt oferowany przez TAURON Sprzedaż dla klientów biznesowych mających lub chcących uzyskać certyfikat oRed dla swoich obiektów.

Spółka obrotu – firma zajmujące się handlem energią, kupująca energię od wytwórców lub przez giełdę i sprzedająca ją odbiorcom końcowym.

Krajowy system elektroenergetyczny – system elektroenergetyczny na obszarze geograficznym Rzeczypospolitej Polskiej.

Niezbilansowanie – niezbilansowanie w rozumieniu art. 2 pkt 8 rozporządzenia 2017/2195, tj. wolumen energii obliczony dla podmiotu odpowiedzialnego za bilansowanie oraz odpowiadający różnicy między przydzielonym wolumenem przypisanym do tego podmiotu a końcową pozycją bilansową tego podmiotu, uwzględniając wszelkie korekty niezbilansowania, zastosowane w przypadku tego podmiotu w danym okresie rozliczania niezbilansowania.

Prosument – odbiorca (osoba lub firma), który wytwarza energię elektryczną w mikroinstalacji fotowoltaicznej (a więc instalacji o mocy maksymalnie 50 kWp). Warunkiem jest, żeby energia wytwarzana w tej instalacji była wytwarzana tylko na

własne potrzeby oraz pochodziła tylko z odnawialnych źródeł energii (a więc nie była dodatkowo zasilana np. agregatem prądotwórczym).

Rynek kontraktowy (terminowy) – rynek obejmujący transakcje zawierane z wyprzedzeniem, w których dostawa energii elektrycznej lub gazu ma nastąpić w przyszłości. Zawarty kontrakt określa zarówno cenę, jak i ilość energii, jaką sprzedawca zobowiązuje się dostarczyć w ustalonym czasie. Rynek terminowy daje uczestnikom pewność, co do ceny i ilości dostarczanej energii, pozwalając na lepsze zarządzanie ryzykiem cenowym.

Rynek spotowy – rynek obejmujący transakcje kupna-sprzedaży energii lub gazu, gdzie dostawa ma miejsce niemal natychmiast lub w bardzo krótkim czasie (zazwyczaj w ciągu 24 godzin). Cena jest ustalana na podstawie bieżącej podaży i popytu. W związku z tym, ceny mogą być bardzo zmienne i często odzwierciedlają aktualne warunki rynkowe.

Rynek bilansujący – rynek służący do zapewnienia równowagi pomiędzy podażą a popytem na energię elektryczną lub gaz w czasie rzeczywistym. Ponieważ zapotrzebowanie na energię może się zmieniać w ciągu dnia, a produkcja energii (szczególnie z odnawialnych źródeł, takich jak fotowoltaika lub turbiny wiatrowe) może być zmienna, więc rynek bilansujący umożliwia dostawcom systemowym dokonywanie korekt w produkcji lub zapotrzebowaniu na energię, aby uniknąć przerw w dostawach.

Odbiorca – odbiorca w rozumieniu art. 3 pkt 13 ustawy Prawo energetyczne, tj. każdy, kto otrzymuje lub pobiera energię elektryczną na podstawie umowy z przedsiębiorstwem energetycznym.

Odbiorca końcowy – odbiorca końcowy w rozumieniu art. 3 pkt 13a ustawy Prawo energetyczne, tj. odbiorca dokonujący zakupu energii elektrycznej na własny użytek; do własnego użytku nie zalicza się energii elektrycznej zakupionej w celu jej magazynowania lub zużycia na potrzeby wytwarzania, przesyłania lub dystrybucji.

Odnawialne źródło energii – odnawialne źródło energii w rozumieniu art. 2 pkt 22 ustawy o odnawialnych źródłach energii, tj. odnawialne, niekopalne źródła energii obejmujące energię wiatru, energię promieniowania słonecznego, energię aerothermalną, energię geothermalną, energię hydrothermalną, hydroenergię, energię fal, prądów i pływów morskich, energię otrzymywaną z biomasy, biogazu, biogazu rolniczego oraz z biopłynów.

Wykaz używanych skrótów

AE	– Absolute error
DAM	– Day ahead market
GHI	– Global horizontal irradiance
ICM	– Interdyscyplinarne centrum modelowania
IMGW	– Instytut meteorologii i gospodarki wodnej
IRiESD	– Instrukcja ruchu i eksploatacji sieci dystrybucyjnej
IRiESP	– Instrukcja ruchu i eksploatacji sieci przesyłowej
JB	– Jednostka bilansowa
JG	– Jednostka grafikowa
JWCD	– Jednostka wytwórcza centralnie dysponowana
KSE	– Krajowy system elektroenergetyczny
MAE	– Mean absolute error
MAPE	– Mean absolute percentage error
MB	– Miejsce dostarczania energii elektrycznej rynku bilansującego
MSE	– Mean square error
NN	– Najwyższe napięcie
nN	– Niskie napięcie
nn	– Neural network
NWP	– Numerical weather prediction
OZE	– Odnawialne źródła energii
OSD	– Operator systemu dystrybucyjnego
PC	– Pompa ciepła
POB	– Podmiot odpowiedzialny za bilansowanie
PPE	– Punkt poboru energii elektrycznej
PV	– Instalacja fotowoltaiczna (photovoltaic)
RB	– Rynek bilansujący krajowego systemu elektroenergetycznego
RDN	– Rynek dnia następnego
RMSE	– Root mean square error
TGE	– Towarowa giełda energii
UTC	– Universal time coordinated

1 WSTĘP

1.1 Uzasadnienie podjęcia tematu

Energia zasilająca nasze domy, gałęzie przemysłu i postęp technologiczny jest siłą napędową współczesnego społeczeństwa. Z postępowaniem technologicznym wiąże się transformacja energetyczna, która dokonuje się na naszych oczach [99, 102, 130, 131]. Aby zapewnić stabilne i niezawodne dostawy, kluczowe znaczenie ma prognozowanie zapotrzebowania na energię elektryczną [100, 132, 133]. Proces ten obejmuje złożone, wzajemne oddziaływanie różnych czynników, od wzorców pogodowych i zachowań społecznych po postęp technologiczny i trendy gospodarcze oraz społeczne. Istotny wpływ na zapotrzebowanie na energię elektryczną mają rozwój i dostępność masowa nowych technologii (np. generacji PV) oraz pojawienie się nowej kategorii użytkowników, jakimi są prosumenci [103, 104, 105]. W krótkoterminowym horyzoncie prognozowania zmiany zachodzące w atmosferze mogą być bardzo dynamiczne i nieprzewidywalne, wpływając na poziom generacji i zapotrzebowania na energię elektryczną [101]. Zmiany sezonowe, wahania temperatury i ekstremalne zjawiska pogodowe bezpośrednio wpływają na ilość zużywanej energii elektrycznej przez człowieka. Podczas upalnego lata lub mroźnej zimy zapotrzebowanie na moc w systemach chłodniczych i grzewczych gwałtownie rośnie, co prowadzi do wzrostu zużycia energii elektrycznej i gazu ziemnego.

Aby model dokładnie prognozował zapotrzebowanie na energię elektryczną, należy zintegrować w nim historyczne dane pogodowe i dane o zapotrzebowaniu na energię elektryczną. Aby model prognostyczny mógł być użyteczny, należy zasilić go predykcjami meteorologicznymi. Nie bez znaczenia jest tu zrozumienie zachowań społecznych i wzorców zużycia energii. Wzrost populacji, urbanizacja, zmiany stylu życia i zmiany we wzorcach pracy wpływają na sposób, w jaki ludzie korzystają z energii elektrycznej. Wydarzenia ostatnich lat dobitnie to pokazały. Na przykład upowszechnienie się pracy zdalnej, w związku z postępowaniem technologicznym i wydarzeniami o zasięgu globalnym, takimi jak pandemia COVID-19, zmienił typowe wzorce zużycia energii naszych gospodarstw domowych i biur, w których pracujemy [106, 107].

Sprzedają energię elektrycznej i gazu ziemnego w Polsce zajmują się tzw. spółki obrotu. Do podejmowania decyzji dotyczących zakupu i sprzedaży energii elektrycznej i gazu ziemnego wykorzystują prognozy zapotrzebowania na te nośniki energii. Zaawansowane analizy predykcyjne umożliwiają tym przedsiębiorstwom optymalizację kosztów dostaw tych mediów odbiorcom, dzięki czemu mogą osiągnąć przewagę konkurencyjną na rynku. Innym pozytywnym efektem może być wykreowanie nowych usług i ofert dla swoich klientów. Takim przykładem może być wdrożenie usługi elastyczności czy wprowadzenie nowych taryf, obniżających koszty zakupu energii elektrycznej przez klientów. Wprowadzenie taryf dynamicznych, w których klienci są zachęceni ekonomicznie do ograniczania lub zwiększania zapotrzebowania, będzie dodatkowo zaburzało standardowy profil zapotrzebowania odbiorców energii elektrycznej.

Rynek energii elektrycznej zmienił się bardzo mocno na przestrzeni ostatnich lat. W 2007 roku zaczęto wdrażać proces unbundling [108], co oznaczało wydzielenie ze zintegrowanych spółek energetycznych części firmy zajmującej się obrotem i części zajmującej się dystrybucją energii elektrycznej. Przed 2007 rokiem działalność była prowadzona w ramach jednego przedsiębiorstwa. Po 2007 roku wprowadzono możliwość wyboru oferty różnych sprzedawców energii elektrycznej, co umożliwiło swobodny dostęp odbiorcom do różnych ofert rynkowych. Sprzedawców energii elektrycznej zachęciło do konkutowania o odbiorców na wolnym rynku. Liberalizacja rynku energii elektrycznej to proces, w którym dostawcy energii (spółki obrotu) mogą swobodnie konkutować ze sobą, wykorzystując infrastrukturę energetyczną (sieci przesyłowe i dystrybucyjne) zarządzane przez OSP i OSD. Z jednej strony prowadzi to do obniżenia cen energii i zwiększenia wyboru dla konsumentów z drugiej zaś stwarza wyzwania dla operatorów systemów przesyłowych i dystrybucyjnych, którzy muszą zapewnić stabilne dostawy energii.

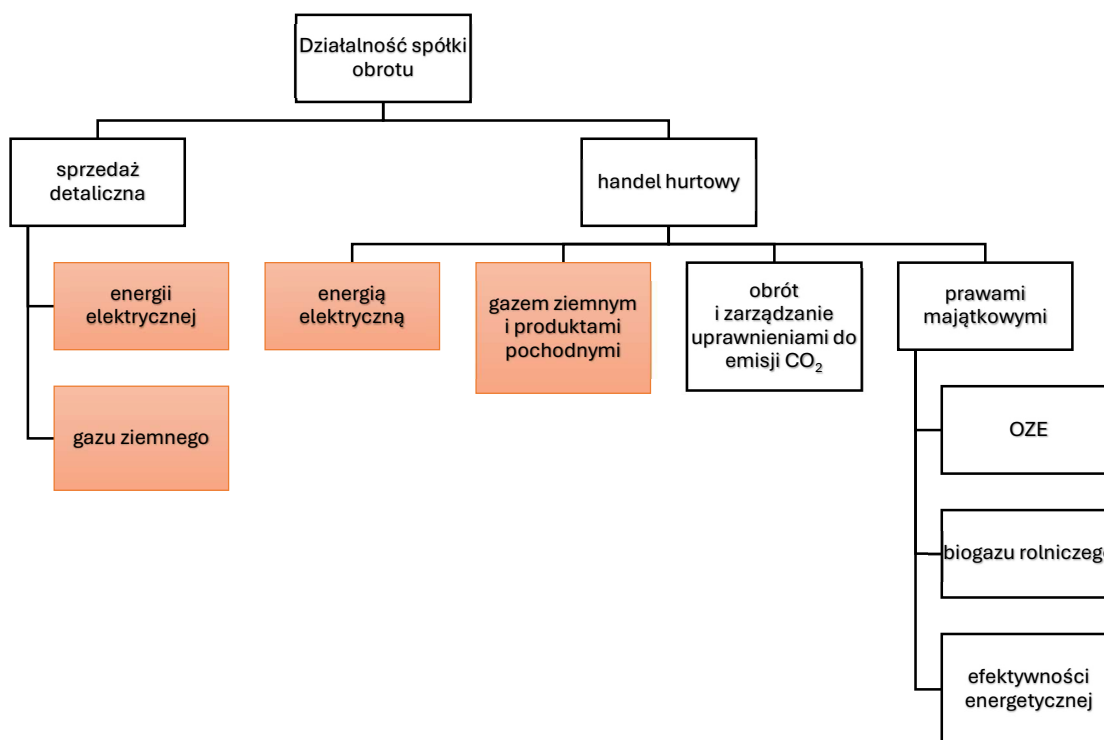
Duże zmiany na rynku wprowadził dynamiczny rozwój energetyki odnawialnej. Zmiany te zostały spotęgowane w latach 2015-2022, dzięki wprowadzeniu możliwości wytwarzania energii elektrycznej i wprowadzaniu ich nadwyżek do sieci dystrybucyjnej przez gospodarstwa domowe i firmy. Największe przyrosty mocy zainstalowanej w krajowym systemie energetycznym w tamtym czasie odnotowała technologia mikroinstalacji fotowoltaicznych. Wprowadzony został nowy model mikrogeneracji, w której każde gospodarstwo domowe lub firma może zostać prosumentem, czyli wytwarzać energię elektryczną na własne potrzeby. W latach 2023 i 2024 dalszy przyrost mocy zainstalowanej w PV został ograniczony przez zmianę systemu rozliczenia z net meteringu (system, który umożliwiał wirtualne magazynowanie w sieci) na net billing (system, w którym energia jest sprzedawana po cenach rynkowych). Jednak wzrost cen energii wywołany wzrostem cen surowców energetycznych oraz spadek cen instalacji PV spowodował, że pod pewnymi warunkami inwestycja w instalację PV jest nadal opłacalna [109]. Szczególnie rozwój energetyki fotowoltaicznej oraz net metering wprowadził konieczność opracowania nowych metod i technik prognozowania zapotrzebowania na energię elektryczną. Zmianie uległ godzinowy profil zapotrzebowania klientów na energię elektryczną. W ostatnich latach znacząco wzrosła liczba użytkowników, dla których źródłem ogrzewania stała się energia elektryczna, ze szczególnym uwzględnieniem pomp ciepła [110]. Ekologicznym i opłacalnym ekonomicznie źródłem ciepła jest gruntowa pompa ciepła, która charakteryzuje się wysokim SCOP [112]. Mniej korzystna jest pompa ciepła typu powietrze woda, której sprawność jest silnie skorelowana z temperaturą powietrza [111]. Najmniej efektywne rozwiązanie, które jednak jest stosowane z uwagi na niskie koszty inwestycyjne to ogrzewanie wykorzystujące prawo Joule'a, tzw. oporowe [113]. Takie rozwiązanie stosowane było często w połączeniu z instalacją fotowoltaiczną [114], gdy obowiązywały zasady rozliczeń typu net metering. Od wprowadzenia rozliczeń typu net billing taka inwestycja nie ma uzasadnienia, z uwagi na brak korelacji pomiędzy zapotrzebowaniem na energię elektryczną a generacją energii elektrycznej z instalacji fotowoltaicznej.

Generacja z fotowoltaiki zapewnia pokrycie szczególnie wrażliwych w okresie letnim szczytów zapotrzebowania w krajowym systemie energetycznym, spowodowanych uruchamianiem klimatyzacji w upalne dni. W przypadku dni pochmurnych, w związku z brakiem generacji przez źródła fotowoltaiczne, zapotrzebowanie na energię elektryczną gwałtownie rośnie. W kolejnych latach należy się spodziewać dalszego wzrostu generacji ze źródeł odnawialnych, możliwej zmiany profilu zapotrzebowania firm i przemysłu, ze względu na rynek mocy oraz taryfy dynamiczne. Powyższe czynniki w jeszcze większym stopniu uzależniają zapotrzebowanie na energię elektryczną od warunków meteorologicznych.

W przypadku spółek obrotu energią elektryczną liczba klientów może zmieniać się w dowolnym dniu roku, w zależności, na jaki okres została zawarta umowa sprzedaży energii elektrycznej z odbiorcą. Regulacje zawarte w Instrukcji Ruchu i Eksploatacji Sieci Dystrybucyjnej stanowią, że aby zmiana sprzedawcy była skuteczna, należy wypowiedzieć dotychczasową umowę i zgłosić wniosek o zmianę sprzedawcy do OSD najpóźniej na 21 dni przed planowaną zmianą. W praktyce najczęstszym terminem zmiany sprzedawcy jest pierwszy dzień roku, chociaż często może to być pierwszy dzień dowolnego miesiąca. Klienci są rozproszeni po całym kraju, dlatego należy ich zareagować, uwzględniając lokalizację geograficzną. Największy wpływ na zapotrzebowanie na energię elektryczną ma temperatura. Z kolei największy wpływ na generację fotowoltaiczną mają natężenie promieniowania słonecznego i temperatura. Warunki atmosferyczne w szerokościach geograficznych Polski zmieniają się dynamicznie. Rzadko się zdarza tydzień o takiej samej lub podobnej pogodzie. Dlatego algorytm musi być wystarczająco prosty i odporny na zmienność w danych. Ze względu na te wymagania najwięcej uwagi poświęcono procesowi inżynierii cech i odkryciu czynników, które są istotne dla profilu zużycia energii klientów.

Spółka obrotu wywodzi się i korzysta z dorobku oraz doświadczeń firm energetycznych o ponad 100-letniej tradycji. Podstawowym zakresem działalności jest sprzedaż energii elektrycznej, co przedstawiono na rysunku 1.1. Na schemacie kolorem pomarańczowym zaznaczono działalność, która jest bezpośrednio powiązana z zakresem badawczym, przedstawionym w tej rozprawie. Handel energią elektryczną i gazem ziemnym stanowi zdecydowaną większą część prowadzonej działalności. Spółka powstała w wyniku wielu podziałów i połączeń organizacyjnych, wynikających z uwarunkowań rynkowych oraz wymogów Dyrektyw Unijnych. Spółka obrotu jest jednym z największych sprzedawców energii elektrycznej w Polsce, sprzedaje energię dla ponad 5,3 mln klientów na terenie całego kraju oraz – w mniejszej skali – na rynkach czeskim i słowackim. W 2014 roku działalność została rozszerzona o sprzedaż paliwa gazowego. Działalność spółki obrotu polega z jednej strony na sprzedaży energii elektrycznej i gazu do klientów, a z drugiej na możliwie jak najlepszym pod względami ilościowym i kosztowym zakupie jej na rynku: terminowym, spotowym lub bilansującym. W praktyce umowy zakupu energii elektrycznej i gazu ziemnego na rynku konkurencyjnym określają ilość, która zostanie pobrana w poszczególnych godzinach doby, w przypadku energii lub w całej dobie, w przypadku gazu. Ilości energii

elektrycznej i gazu ziemnego potrzebnej w każdej jednostce czasu określane są na podstawie sporządzanych prognoz zapotrzebowania, które na końcowym etapie są agregowane. Ostateczna prognoza jest podstawą do zakupu\sprzedaży odpowiedniej ilości na rynku spot.



Rys. 1.1. Działalność handlowa spółki obrotu

Fig. 1.1. Commercial activity of the trading company

W 2024 roku główny wpływ na ceny energii elektrycznej miała cena wytworzenia energii z węgla kamiennego i brunatnego (około 75% udziału w miksie energetycznym). Drugą istotną pozycją była cena uprawnień do emisji CO₂, która obecnie stanowi około 50% ceny energii elektrycznej notowanej na giełdzie. Najniższy udział w koszcie energii elektrycznej mają prawa majątkowe, które spółka obrotu musi nabyć w ilości określonej przez ustawę o odnawialnych źródłach energii (OZE). Ostateczna cena zawiera jeszcze marżę spółki obrotu oraz podatki vat i akcyzę. Cena energii elektrycznej lub gazu ziemnego może być zmienną objaśniającą zapotrzebowanie [86, 87, 88], ale to właśnie w prognozowaniu cen najczęściej wykorzystywaną zmienną objaśniającą jest wielkość zapotrzebowania.

Trzeba również zauważyć, że prognozy zapotrzebowania na gaz będą z czasem miały coraz mniejsze znaczenia, ze względu na odchodzenie w przyszłości od tego nośnika. Odwrotnie sytuacja wygląda dla rynku energii elektrycznej, gdzie udział nośnika stale rośnie, a problemy związane z predykcją pogłębiają się, ze względu na coraz większy wolumen produkcji ze źródeł odnawialnych.

Biorąc powyższe pod uwagę, należy stwierdzić, że podjęta tematyka ma nie tylko duże znaczenie i wpływ na wyniki finansowe spółek, ale również walory poznawcze w sensie naukowym.

1.2 Cel badań i zakres pracy

Jako główny cel badań przyjęto opracowanie i wdrożenie efektywnej metody progностycznej, połączonej z opracowaniem skutecznego algorytmu krótkoterminowego prognozowania zapotrzebowania na energię elektryczną i gaz ziemny. Jako miarę oceny jakości nowej metody przyjęto poprawę trafności jej prognoz w stosunku do aktualnie używanych metod.

Zidentyfikowanie przyczyn błędów pojawiających się w prognozach oraz wskazanie metod, które mogą ograniczać powstanie tych błędów jest punktem wyjścia do opracowania nowej metodyki. Cel główny zostanie osiągnięty przez realizację licznych celów szczegółowych, wśród których można wymienić:

- określenie czynników wpływających na poziom zapotrzebowania na energię elektryczną i gaz,
- określenie wpływu generacji OZE na prognozy zapotrzebowania,
- ocena wpływu błędów prognoz meteorologicznych na prognozę poziomu zapotrzebowania,
- wyznaczenie optymalnych parametrów agregacji danych historycznych oraz ocena metody prognozy zagregowanej oraz zdezagregowanej,
- oszacowanie kosztów niedokładności prognoz zapotrzebowania.

Istotnym elementem jest również opracowanie zagadnień uzupełniających, związanych z oceną wpływu na prognozy zapotrzebowania na energię elektryczną i gaz:

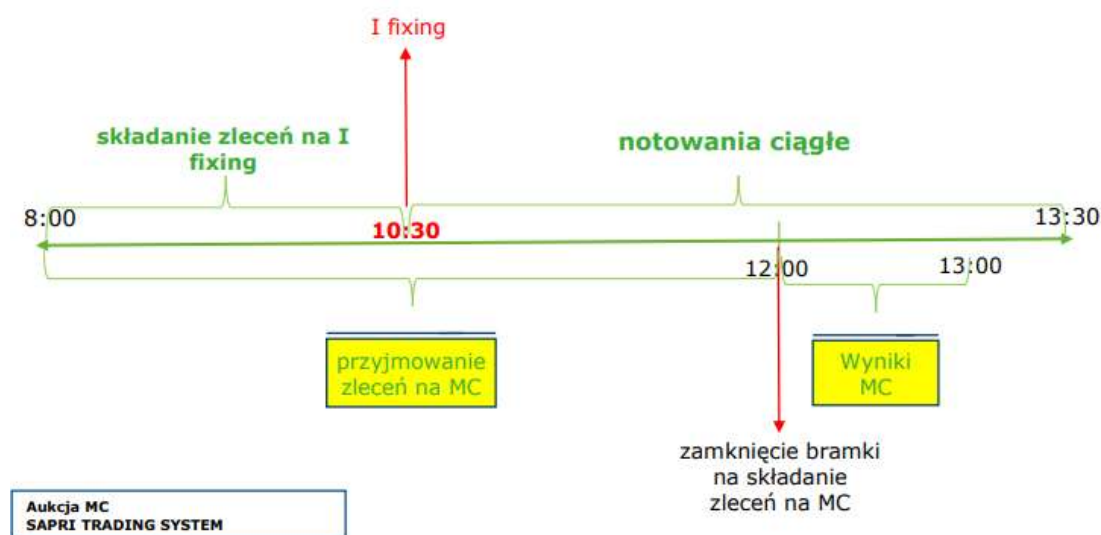
- dokładności otrzymywanych prognoz meteorologicznych,
- zmienności i poprawności analizowanych danych historycznych.

W kolejnych rozdziałach przedstawione zostaną wyniki badań, dotyczących powyższych punktów.

2 AKTUALNY STAN WIEDZY

2.1 Charakterystyka funkcjonowania handlu energią elektryczną i gazem ziemnym w Polsce

Spółki obrotu dokonują zakupu energii elektrycznej lub gazu na giełdzie lub bezpośrednio od wytwórców, a następnie sprzedają ją końcowym odbiorcom. Krajowy rynek energii w Polsce dzieli się na trzy podstawowe segmenty: rynek kontraktowy, rynek spotowy i rynek bilansujący. Rynek terminowy służy do handlu w horyzoncie od minimum tygodnia (produkty standardowe typu „week”) do maksymalnego wyprzedzenia, jakim jest obecnie horyzont 3 lat (produkt standardowy typu „year”). W ramach handlu na rynku terminowym zawiera się transakcję z ceną ustaloną z wyprzedzeniem na określony termin dostawy. Harmonogram notowań na rynku dnia następnego przedstawiono na schemacie 2.1.



Rys. 2.1. Harmonogram notowań na rynku dnia następnego na TGE [7]

Fig. 2.1. Day-ahead market quotation schedule on TGE [7]

Obrót energią elektryczną i gazem ziemnym na rynku transakcji natychmiastowych (spot) odbywa się w ramach transakcji krótkoterminowych, z wyprzedzeniem jednego dnia lub w ramach dnia, w którym następuje dostawa. W ramach rynku spot handluje się znaczną ilością energii elektrycznej i gazu ziemnego. Pozwala to spółkom obrotu na zrównoważenie wahań zapotrzebowania i zakupu odpowiedniej ilości energii na pokrycie zapotrzebowanej w określonym terminie dostawy.

Cena energii elektrycznej na poszczególne godziny kolejnej doby (RDN)

w PLN za megawatogodzinę (PLN/MWh), godzinowo



Rys. 2.2. Wyniki notowań na TGE przedstawiające godzinowe ceny oraz wolumeny energii elektrycznej [12]

Fig. 2.2. Results of quotations on TGE presenting hourly prices and volumes of electricity [12]

Cena transakcji dla każdej godziny w przypadku energii elektrycznej (w przyszłości ma zostać wprowadzony handel na kwadransie zamiast godziny) i doby w przypadku gazu ziemnego ustalana jest w dwóch seriach (fixingach) poprzedniego dnia. Transakcje zawierane są przez 7 dni w tygodniu na rynku dnia następnego towarowej giełdy energii (rynek typu spot). Przykładowe wyniki notowania energii elektrycznej przedstawiono na wykresie 2.2. Na fixing składa się oferty kupna i sprzedaży energii (bez uwzględnienia możliwości wymiany handlowej z połączonymi rynkami za granicą), które są ze sobą kojarzone. Oferty są składane od 8:00 do 10:30 w dniu poprzedzającym fizyczną dostawę energii. O 10:30 określany jest kurs dla wszystkich godzin dostawy. Fixing II to kolejna faza składania ofert, w której uwzględnia się możliwości wymiany handlowej z połączonymi rynkami za granicą. Oferty są publikowane o 11:15, a o 13:30 określa się kurs dla wszystkich godzin dostawy. W przypadku zakontraktowania zbyt dużej ilości energii na rynku terminowym, może nastąpić sprzedaż, a w przypadku niewystarczającej ilości zakup. Do pozycji ustalonej w ramach rynku spot następuje rozliczenie nadwyżek i braków po cenach rynku bilansującego.

Rynek bilansujący jest kluczowym elementem hurtowego rynku energii elektrycznej w Polsce. Jego główne cele to zapewnienie równoważenia energii elektrycznej wytworzonej w systemie elektroenergetycznym z zapotrzebowaniem odbiorców na energię elektryczną oraz zarządzanie ograniczeniami systemowymi, w celu zapewnienia ciągłości i właściwej jakości dostaw energii. Rynek bilansujący w Polsce jest zarządzany przez OSP i funkcjonuje na podstawie modelu centralnego dysponowania. Oznacza to, że OSP odpowiada za dobór i dysponowanie mocą jednostek wytwórczych centralnie dysponowanych. Jednostki JWCD to jednostki wytwórcze, które mogą być uruchamiane lub wyłączane na polecenie OSP, w celu

zapewnienia równoważenia bilansu energii. OSP zapewnia infrastrukturę techniczną dla rynku bilansującego oraz odpowiada za jego prawidłowy przebieg. Uczestnikami rynku bilansującego mogą być:

- dostawcy usług bilansujących (DUB),
- podmioty odpowiedzialne za bilansowanie (POB),
- operatorzy systemu przesyłowego i systemów dystrybucyjnych.

DUB to podmioty świadczące usługi bilansowania, czyli usługi polegające na dostarczaniu lub pobieraniu energii elektrycznej, w celu zapewnienia równoważenia bilansu energii w krajowym systemie elektroenergetycznym. POB to podmioty, które są odpowiedzialne za zapewnienie równoważenia bilansu energii elektrycznej w swoim zakresie. W przypadku przedsiębiorstw energetycznych, które mają własne wytwórcze jednostki energetyczne, POB-em jest to przedsiębiorstwo. W przypadku odbiorców energii elektrycznej, którzy nie mają własnych wytwórczych jednostek energetycznych, POB-em jest dostawca energii elektrycznej. Operatorzy systemu przesyłowego i systemów dystrybucyjnych są uczestnikami rynku bilansującego w zakresie zakupu energii elektrycznej, w celu pokrywania strat w ich sieciach.

Rynek bilansujący dzieli się na dwa okresy rozliczeniowe:

- okres dobowy, który obejmuje jeden dzień kalendarzowy,
- okres godzinowy, który obejmuje jedną godzinę.

W ramach każdego okresu rozliczeniowego odbywa się trzyetapowy proces bilansowania:

1. Planowanie – OSP opracowuje plan bilansu energii elektrycznej na podstawie informacji o transakcjach zawartych na rynkach giełdowym i bilateralnym oraz danych handlowych i technicznych, dotyczących poszczególnych jednostek wytwórczych i odbiorczych.
2. Wykonanie – OSP dysponuje mocą jednostek wytwórczych, w celu zapewnienia równoważenia bilansu energii.
3. Rozliczenie – OSP rozlicza uczestników rynku bilansującego za ich udział w procesie bilansowania.

Uczestnicy rynku bilansującego, którzy dostarczyli energię elektryczną, otrzymują za nią wynagrodzenie, a uczestnicy, którzy pobrali energię elektryczną są obciążeni kosztami jej zakupu. Wynagrodzenie za dostarczoną energię elektryczną jest wypłacane na podstawie ceny rynkowej energii elektrycznej. Koszty zakupu energii elektrycznej są ustalane przez OSP. Terminem na złożenie ofert bilansujących jest okres 24 godzin przed rozpoczęciem danego okresu rozliczeniowego. Terminem rozpoczęcia realizacji planu bilansu energii elektrycznej jest godzina 00:00 w dniu rozpoczęcia danego okresu rozliczeniowego. Terminem zakończenia realizacji planu bilansu energii elektrycznej jest 23:59 w dniu zakończenia danego okresu rozliczeniowego. Mając na uwadze ten ogólny zarys funkcjonowania rynku energii elektrycznej, można przejść do rozważań nad metodami prognozowania zapotrzebowania na energię elektryczną [55].

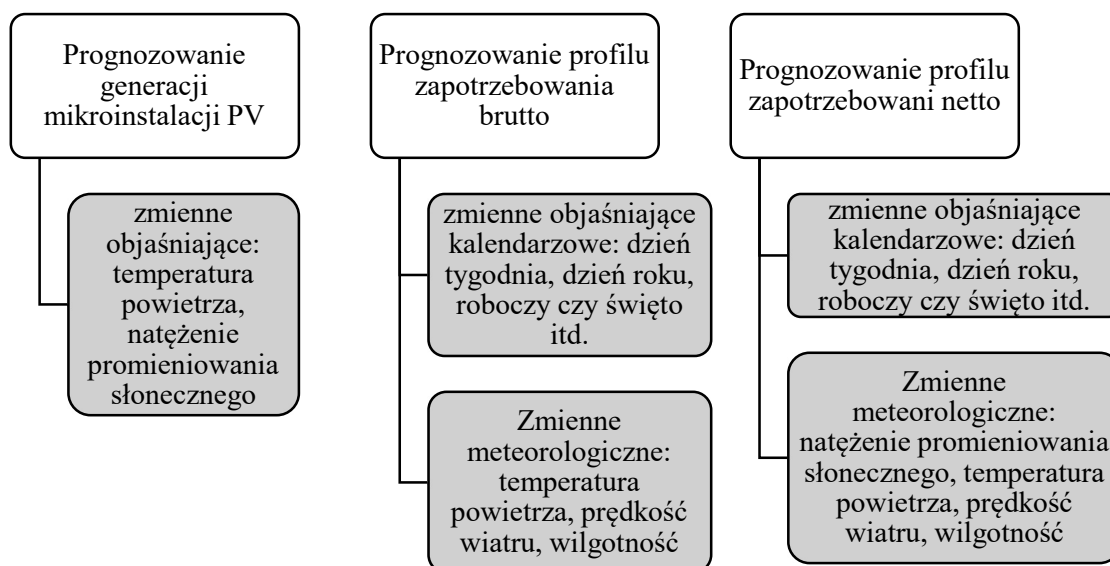
2.2 Techniki prognozowania i analizy danych

Źródłem informacji do identyfikacji trendów i sezonowości jest analiza danych historycznych. Na przykład, jeśli zapotrzebowanie na energię elektryczną rosło w tempie 2% rocznie w ciągu ostatnich 10 lat, to można założyć, że będzie rosło w tym samym tempie w przyszłości. Zazwyczaj jednak pojawiają się odchylenia od trendu spowodowanego różnego rodzaju niespodziewanymi wydarzeniami, jak np. kryzys finansowy w 2008 roku, lockdown z powodu pandemii w 2020 roku, kryzys energetyczny w 2022 roku. Niektóre trendy mogą zostać zmienione również pod wpływem rozwijających się nowych technologii. Prognozowanie z wykorzystaniem trendów jest skuteczne w przypadku prognoz średnioterminowych i długoterminowych. Dla prognoz krótkoterminowych bardziej uzasadnione jest stosowanie prognoz przyczynowo skutkowych [115]. W takim podejściu analizuje się dane historyczne pod kątem czynników, które mogą wpływać na zapotrzebowanie na energię, takie jak pogoda, ceny energii i poziom aktywności gospodarczej. W różnych krajach i systemach energetycznych szacowana jest zależność zapotrzebowania na energię elektryczną, np. od temperatury. W zdecydowanej większości przypadków potwierdzona została zależność wzrostu zapotrzebowania na energię elektryczną podczas upałów, ale również wzrostu zapotrzebowania w przypadku mrozów. Prognozowanie zapotrzebowania u klientów korzystających z mikroinstalacji fotowoltaicznych można poprawić za pomocą oddzielenia użytkowników z PV od użytkowników bez PV i wykorzystania różnych modeli do wykonania prognoz na podstawie typów pogody [117]. Od czasu wprowadzenia w Polsce możliwości wytwarzania energii elektrycznej przez odbiorców na własne potrzeby oraz wprowadzania nadwyżek wyprodukowanej energii do sieci elektroenergetycznej, prognozowanie zapotrzebowania na energię musi uwzględnić rosnący udział mikroinstalacji za licznikami OSD.

Zapotrzebowanie odbiorców z mikroinstalacjami OZE (prosumentów) można prognozować metodą [116]:

1. pośrednią:
 - modelowanie zapotrzebowania brutto,
 - modelowanie generacji,
2. bezpośrednią:
 - modelowanie zapotrzebowania netto, uwzględniające wpływ mikroinstalacji.

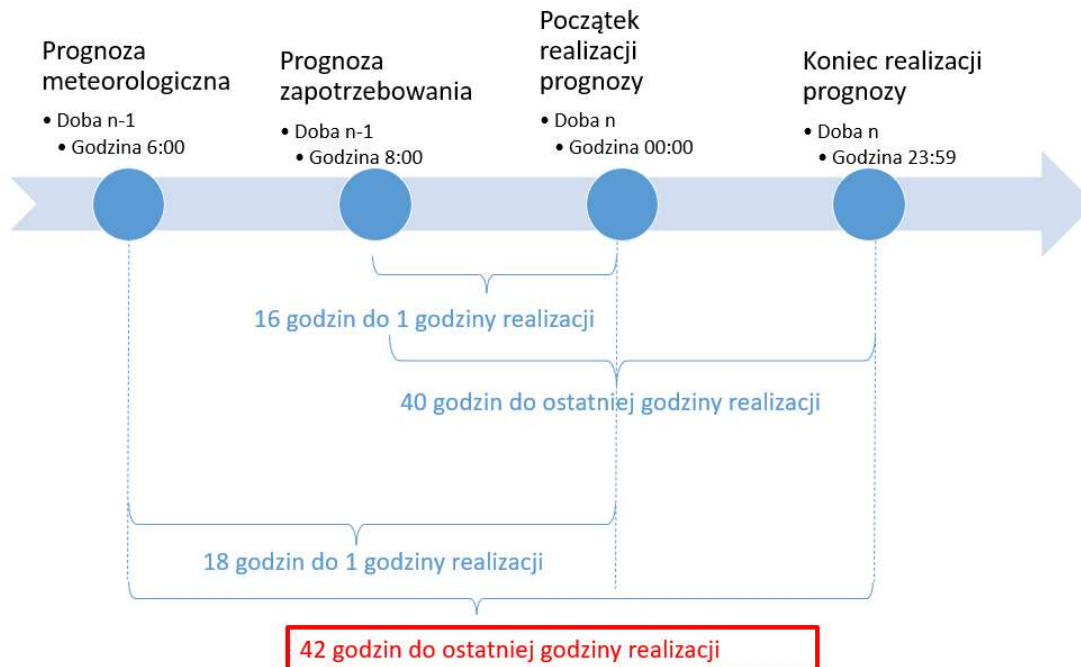
W metodzie pośredniej składowa zapotrzebowania brutto jest dodawana do składowej generacji, która jest wartością ujemną. Powyższe metody wraz z potencjalnymi zmiennymi objaśniającymi zostały przedstawione na wykresie 2.3.



Rys. 2.3. Zmienne objaśniające używane do prognozowania zapotrzebowania w metodach pośredniej oraz bezpośredniej

Fig. 2.3. Explanatory variables used for demand forecasting in the direct and indirect methods

Prognozowanie zapotrzebowania na energię elektryczną i gaz realizowane w spółce obrotu jest powiązane z handlem na TGE i odbywa się w horyzoncie krótkoterminowym (na 1 dzień wprzód), co przedstawia poglądowo poniższy harmonogram – rys. 2.4:



Rys. 2.4. Poglądowy harmonogram przygotowania prognoz zapotrzebowania

Fig. 2.4. Indicative schedule for preparing demand forecasts

W odpowiedzi na realizację powyższego harmonogramu, prognoza meteorologiczna jest przygotowywana w określonym terminie i horyzoncie na zamówienie spółki obrotu. Skorzystanie z innych modeli może wydłużyć harmonogram, czyli odległość pomiędzy generacją prognozy meteorologicznej a godziną realizacji tej prognozy. Najczęściej wybierane modele numeryczne, które potrafią obliczyć prognozy warunków meteorologicznych atmosfery, przedstawiono w tabeli 2.1. Modele pogodowe obejmują różne obszary geograficzne w różnych rozdzielczościach i zapewniają różne zmienne pogodowe. W zależności od modelu dane mogą być interpolowane na wartości godzinowe lub kwadransowe [10].

Tab. 2.1 Dostawcy popularnych modeli meteorologicznych

Tab. 2.1. Suppliers of popular meteorological models

Model	Dostawca	Kraj pochodzenia	Rozdzielczość	Długość prognozy	Częstotliwość generacji prognoz
ICON	Deutscher Wetterdienst (DWD)	Niemcy	2-11 km	7,5 dnia	Co 3 godziny
GFS & HRRR	NOAA	USA	3-25 km	16 dni	Co godzinę
ARPEGE & AROME	Météo-France	Francja	1-25 km	4 dni	Co godzinę
IFS & AIFS	ECMWF	Unia Europejska	25 km	7 dni	Co 6 godzin
MSM & GSM	JMA	Japonia	5-55 km	11 dni	Co 3 godziny
MET Nordic	MET Norway	Norwegia	1 km	2,5 dnia	Co godzinę
GEM	Canadian Weather Service	Kanada	2,5 km	10 dni	Co 6 godzin
GFS GRAPES	China Meteorological Administration (CMA)	Chiny	15 km	10 dni	Co 6 godzin
ACCESS-G	Australian Bureau of Meteorology (BOM)	Australia	15 km	10 dni	Co 6 godzin
COSMO 2I	AM ARPAE ARPAP	Włochy	2 km	3 dni	Co 3 godziny

W zależności od dostępności danych historycznych lub ich braku, modele mogą być szacowane na historycznych prognozach. Istnieją zatem trzy możliwe kombinacje oszacowania modeli prognostycznych:

- Model może być oszacowany na zmiennych rzeczywistych (dane pomiarowe, np. GHI, zmierzone piranometrem lub temperatura zmierzona termometrem), a prognozy generowane na prognozach meteorologicznych.

- W przypadku braku danych rzeczywistych model można szacować na historycznych zmiennych prognozowanych.
- Model można również przeliczyć na zmiennych rzeczywistych powykonawczo. Jest to testowanie wsteczne modeli, które pozwala na oszacowanie błędu spowodowanego przez błąd prognoz zmiennych objaśniających.

2.3 Prognozowanie zapotrzebowania odbiorców gazu ziemnego

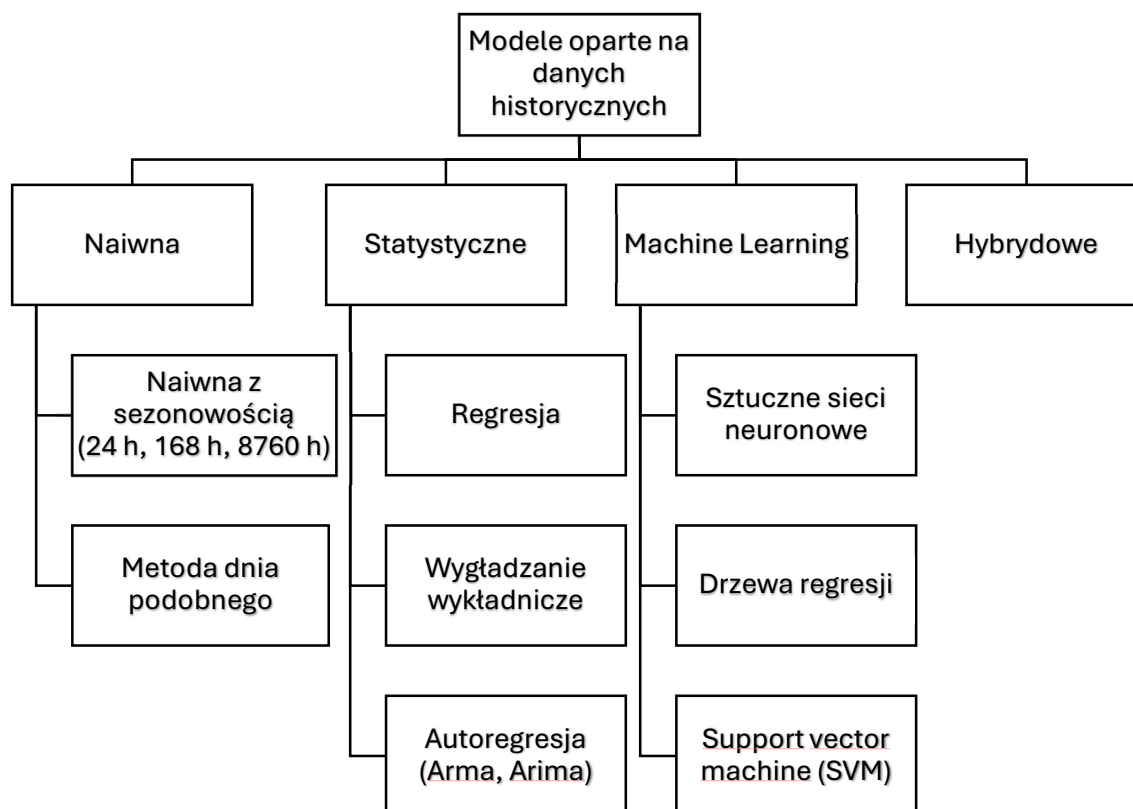
Obrót handlowy gazem ziemnym na rynku dnia następnego (RDN, Day-Ahead Market, DAM) to mechanizm, w którym transakcje zakupu i sprzedaży gazu ziemnego są zawierane z jednodniowym wyprzedzeniem, na podstawie przewidywanego zapotrzebowania i podaży. Rynek ten pozwala uczestnikom handlować gazem na dzień przed jego fizyczną dostawą, zapewniając elastyczność i możliwość dostosowania się do bieżących warunków rynkowych. Spółka obrotu w swoim portfelu ma klientów z większości grup taryfowych. Agregacja klientów jest analogiczna do energii elektrycznej. Podobnie odbywa się proces prognozowania zapotrzebowania na gaz w dobie n na dobę $n+1$. Różnicą jest to, że prognozy zapotrzebowania na energię elektryczną przygotowuje się na każdą godzinę, a w przypadku gazu ziemnego – na całą dobę.

Zapotrzebowanie na gaz ziemny w różnych gałęziach gospodarki będzie kształtowało się w zależności od kilku kluczowych czynników, takich jak polityka klimatyczna, postęp technologiczny oraz dostępność alternatywnych źródeł energii. Ogrzewanie budynków mieszkalnych gazem w Polsce jest coraz mniej perspektywiczne z kilku powodów. Od 2030 roku wszystkie nowo budowane budynki powinny być zeroemisyjne, co oznacza, że będą musiały korzystać z odnawialnych źródeł energii. W modernizowanych budynkach kotły gazowe będą mogły być instalowane do 2040 roku. Ponadto koszty ogrzewania gazem będą rosły, podczas gdy koszty eksploatacji pomp ciepła mają spadać. Polska, podobnie jak inne kraje UE, dąży do redukcji emisji CO₂. Gaz ziemny, choć emituje mniej CO₂ niż węgiel, wciąż jest paliwem kopalnym, które w przyszłości ma być zastąpione bezemisyjnymi źródłami energii. W związku z tym, promowane będą bardziej ekologiczne rozwiązania. Powyższe założenia sprawiają, że ogrzewanie gazowe staje się coraz mniej konkurencyjne i opłacalne. Elektrownie i elektrociepłownie gazowe są jednym z największych konsumentów gazu ziemnego w Polsce, ale jego rola w tej branży będzie się zmieniać. Przewiduje się, że krótko- i średnioterminowo, tj. do 2030 roku gaz ziemny może być wykorzystywany jako paliwo przejściowe w sektorze energetycznym, zwłaszcza w elektrociepłowniach, w celu zastępowania węgla i stabilizowania systemu energetycznego w czasie przechodzenia na odnawialne źródła energii. Natomiast długoterminowo, tj. po 2030 roku w miarę wzrostu udziału OZE w miksie energetycznym, a także w rozwoju technologii magazynowania energii rola gazu w energetyce będzie maleć. Po 2040 roku użycie gazu ziemnego w elektrowniach będzie ograniczone, a elektrownie gazowe będą używane jedynie jako rezerwa do bilansowania systemu elektroenergetycznego.

Część z badaczy analizuje wykorzystanie łatwiejszych technik, jak np. regresji wielomianowej [43, 44, 45], a część skupia się na bardziej skomplikowanych technikach, jak np. sieci neuronowe [50, 51, 52]. Prognozowanie zapotrzebowania na gaz ziemny opiera się na takich samych technikach, jak dla energii elektrycznej. Jako zmienne objaśniające wykorzystywane są dane meteorologiczne (temperatura, wilgotność), które mają kluczowy wpływ na zapotrzebowanie na gaz. W kontekście ogrzewania, w literaturze wykazano silną zależność zapotrzebowania gazu ziemnego od temperatury [47, 48]. Jak wskazano w pracy [49], prędkość wiatru w warunkach klimatycznych Polski nie jest silnie skorelowana z zapotrzebowaniem na gaz ziemny. Istotna zmienna, oprócz temperatury i wilgotności powietrza, to opóźnione dane rzeczywiste, np. o 1 dzień lub o 1 tydzień [53]. Często w literaturze można spotkać się z podejściem wykorzystania takich samych metod do prognozowania zapotrzebowania na energię elektryczną jak na gaz ziemny [54]. W niniejszej pracy skupiono się na prognozowaniu zapotrzebowania na energię elektryczną, jednak wykorzystane metody mogą również z powodzeniem być użyte do prognozowania zapotrzebowania na gaz ziemny.

2.4 Stosowane metody i modele

Prognoza zapotrzebowania spółki wykonywana jest za pomocą metody łączącej metody bottom-up i top down [118]. Różnica między podejściami polega na sposobie sprowadzania danych do docelowego poziomu agregacji. W przypadku podejścia bottom-up obliczenia wykonywane są dla poziomów składowych, a następnie agregowane do poziomu wyższego w hierarchii. W przypadku podejścia top-down najpierw wykonywane są obliczenia dla wyższego poziomu w hierarchii, a potem następuje rozdział na niższe poziomy [9]. Przykładem podejścia bottom-up może być wykonywanie prognoz zapotrzebowania dla poszczególnych budynków lub osiedli, a następnie sumowanie ich do prognoz dla całego miasta. W podejściu top-down prognozowana może być moc całego regionu, a następnie rozdzielana na poszczególne miasta za pomocą skalowania proporcjonalnego mocą zainstalowaną. Niezależnie od metody agregacji końcowej prognozy, możliwe jest zastosowanie każdej z technik, opisanej w kolejnych podrozdziałach. Ogólną klasyfikację metod prognostycznych, używanych do prognozowania zapotrzebowania na energię elektryczną, przedstawiono na rysunku 2.5.



Rys. 2.5. Klasyfikacja modeli prognostycznych [134]

Fig. 2.5. Classification of forecasting models [134]

2.4.1 Regresja liniowa

To jeden z najprostszych modeli statystycznych, który pozwala na prognozowanie wartości zmiennych zależnych na podstawie wartości zmiennych niezależnych. Może być stosowany do prognozowania oddania energii do sieci przez prosumentów na podstawie danych dotyczących m.in. historycznego zapotrzebowania na energię elektryczną, prognoz pogody i danych dotyczących historycznego oddania energii do sieci dystrybucyjnej [63, 64]. Wzór na regresję liniową z wieloma zmiennymi (regresja liniowa wieloraka) przedstawiono poniżej:

$$y = \beta + \beta_1 x_1 + \beta_2 x_2 + \beta_n x_n + \varepsilon \quad (2.1)$$

gdzie:

- y – wartość zmiennej zależnej (wynik),
- x_1, x_2, \dots, x_n – wartości zmiennych niezależnych (objaśniających, predyktorów),
- β_0 – wyraz wolny (przecięcie z osią y , intercept),
- $\beta_1, \beta_2, \dots, \beta_n$ – współczynniki regresji dla odpowiednich zmiennych,
- n – liczba zmiennych niezależnych,
- ε – składnik losowy (błąd).

W grupie modeli zawiera się również często stosowany model ARIMA (AutoRegressive Integrated Moving Average). Model jest używany zarówno w prognozowaniu zapotrzebowania, jak i cen na rynku dnia następnego. Jego zastosowanie przedstawia szczegółowo bogata literatura [59, 60, 61, 62]. Jest to model typowo stosowany do szeregów czasowych, który pozwala na prognozowanie wartości zmiennych tylko na podstawie ich własnej historii. Może być stosowany do prognozowania autokonsumpcji prosumentów, biorąc pod uwagę dane historyczne dotyczące wytwarzania i zużycia energii. ARIMA (AutoRegressive Integrated Moving Average) jest kombinacją trzech komponentów: autoregresji (AR), różnicowania (I) i średniej ruchomej (MA). Ogólny wzór na model ARIMA można przedstawić jako:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2.2)$$

gdzie:

y_t – wartość zmiennej w czasie t ,

c – stała (jeśli uwzględniona),

$\phi_1, \phi_2, \dots, \phi_p$ – współczynniki autoregresji (AR),

$y_{t-1}, y_{t-2}, \dots, y_{t-p}$ – wartości zmiennej z wcześniejszych okresów (opóźnienia),

$\theta_1, \theta_2, \dots, \theta_q$ – współczynniki średniej ruchomej (MA),

ε_t – błąd (składnik losowy) w czasie t ,

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ – błędy z poprzednich okresów,

p – rząd autoregresji (liczba opóźnień),

d – stopień różnicowania (liczba różnic),

q – rząd średniej ruchomej (liczba opóźnionych błędów).

2.4.2 Modele uczenia maszynowego i sieci neuronowe

Badania dotyczące uczenia maszynowego, sztuczne sieci neuronowe i technologie AI są obecnie jednym z najbardziej gorących tematów badawczych [119, 120, 121, 122, 123, 124]. Mają one również zastosowanie w przypadku prognozowania zapotrzebowania na energię elektryczną i gaz ziemny. Modele uczenia maszynowego pozwalają na predykcję wartości zmiennych na podstawie wielu czynników. Mogą być stosowane do prognozowania zapotrzebowania, wykorzystując do nauki historyczne dane dotyczące zapotrzebowania na energię (zmiennie opóźnione), prognozy pogody i inne czynniki, wpływające na wytwarzanie i konsumpcję energii. Prace nad modelami prognozowania są intensywnie rozwijane w literaturze. Zastosowanie nowoczesnych metod sztucznej inteligencji i machine learningu, takich jak głębokie sieci neuronowe [21, 79] czy gradient boosting [22, 80], pozwala na uzyskiwanie precyzyjniejszych wyników. Niemniej jednak, skuteczność tych modeli w dużej mierze zależy od jakości oraz zakresu wykorzystywanych danych uczących [23]. Dlatego też odpowiednia

agregacja danych oraz dobór zmiennych predykcyjnych stanowią kluczowe etapy procesu prognozowania.

Wykorzystanie sztucznych sieci neuronowych w prognozowaniu można znaleźć w pracach m.in. Chapagain czy Kiartzis [67, 68], w które dowodzą, że są skuteczne w przewidywaniu zapotrzebowania. Równie dobrze udokumentowane jest wykorzystanie sieci neuronowych w prognozowaniu cen energii [69, 70].

Podstawowym elementem sieci neuronowej jest pojedynczy neuron. Elementarną zależność przedstawiającą jego działanie można zapisać w następujący sposób [125]:

$$y = f \left(\sum_{i=1}^n \omega_i \cdot x_i + b \right) \quad (2.3)$$

gdzie:

y – wyjście neuronu,

x_i – wejścia do neuronu (np. zmienne wejściowe),

w_i – wagi przypisane do wejść x_i ,

b – bias (przesunięcie),

f – funkcja aktywacji (np. sigmoidalna, ReLU itp.).

W wielowarstwowej sieci neuronowej obliczenia są realizowane przez kilka warstw neuronów. Wyjścia z jednej warstwy stają się wejściami do następnej warstwy. Dla sieci z warstwą wejściową, jedną warstwą ukrytą i warstwą wyjściową, wzór przedstawiający obliczenia w warstwie ukrytej można zapisać w następujący sposób [126]:

$$h_j = f \left(\sum_{i=1}^n \omega_{ji} \cdot x_i + b_j \right) \quad (2.4)$$

gdzie:

h_j – wyjście neuronu,

w_{ji} – wagi przypisane do wejść x_i ,

f – funkcja aktywacji.

A w warstwie wyjściowej:

$$y_k = g \left(\sum_{j=1}^m k_{kj} \cdot h_j + c_k \right) \quad (2.5)$$

gdzie:

y_k – wyjście z neuronu w warstwie wyjściowej,

w_{kj} – wagi między ukrytym neuronem j a wyjściowym neuronem k ,

c_k – bias dla neuronu wyjściowego,

g – funkcja aktywacji na wyjściu (może być liniowa lub nieliniowa, w zależności od problemu).

Podczas trenowania sieci neuronowej algorytm uczenia zmienia wagi i biasy, aby minimalizować błąd prognozy (np. funkcję błędu kwadratowego). Najpopularniejszą metodą wykorzystaną do tego celu jest algorytm propagacji wstecznej (backpropagation), który oblicza gradient błędu i aktualizuje wagi zgodnie z:

$$w_i \leftarrow w_i - \eta \frac{\partial E}{\partial w_i} \quad (2.6)$$

gdzie:

η – współczynnik uczenia (learning rate),

E – funkcja błędu (np. różnica między wartościami prognozowaną a rzeczywistą),

$\frac{\partial E}{\partial w_i}$ – pochodna funkcji błędu względem wagi w_i .

Jak podaje Chen [78] extreme gradient boosting (XGBoost) to skuteczna i szeroko stosowana metoda uczenia maszynowego. Model XGBoost stara się zbudować model predykcyjny w formie sumy predykcji z K drzew decyzyjnych, według poniższego wzoru:

$$\hat{y}_i = \sum_{k=1}^K f(k)x_i \quad (2.7)$$

gdzie:

\hat{y}_i – przewidywana wartość dla przykładu i ,

$f_k(x_i)$ – funkcja predykcji drzewa k dla x_i .

Każde f_k należy do przestrzeni F wszystkich możliwych drzew decyzyjnych:

$$F = \left\{ f(x) = w_{q(x)} \right\}, \quad q: \mathbb{R}^m \rightarrow T, w \in \mathbb{R}^T \quad (2.8)$$

gdzie:

$q(x)$ – funkcja przypisująca każdemu x liść w drzewie,

w – wektor wag przypisany do liści.

T – liczba liści w drzewie, a w_j to wagi liści.

Algorytm optymalizuje funkcję kosztu, która składa się z funkcji straty (która mierzy, jak bardzo przewidywane wartości różnią się od rzeczywistych) i regularyzacji (która kontroluje złożoność modelu):

$$L(\emptyset) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{i=1}^n \Omega(f_k) \quad (2.9)$$

gdzie:

$l(y_i, \hat{y}_i)$ – funkcja straty (np. średni błąd kwadratowy),

$\Omega(f_k)$ – funkcja regularyzacji modelu.

W każdym kroku t , XGBoost dodaje nowy model $f_t(x)$ do istniejącego modelu, minimalizując przy tym przybliżenie do gradientów funkcji straty:

$$g_i = \frac{\partial l(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)}} \quad (2.10)$$

$$h_i = \frac{\partial^2 l(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)^2}} \quad (2.11)$$

gdzie:

g_i – gradient funkcji straty,

h_i – hessian (pochodna drugiego rzędu) funkcji straty.

2.4.3 Metoda naiwna

Jedna z najprostszych metod prognozowania, w której przewidywana wartość jest obliczana jako średnia z określonej liczby wcześniejszych obserwacji to średnia ruchoma [127]. Algorytm prognozy można zapisać następująco:

$$y_t = (X_{t-1} + X_{t-2} + X_{t-3} + \dots + X_{t-n})/n \quad (2.12)$$

Metoda naiwna [128] przyjmuje, że przyszła wartość jest równa wartości z ostatniego okresu. Jest często stosowana jako metoda bazowa, ponieważ jest prosta i szybka do obliczenia. Prognozy można wygenerować według wzoru 2.13:

$$y_t = x_{t-1} \quad (2.13)$$

Sezonowa forma metody naiwnej przewiduje wartość na podstawie wcześniejszej wartości z tego samego okresu (np. miesiąca lub tygodnia). Jest to podejście zgodne z praktykami prognozowania w literaturze [66], a wzór (2.14) został przedstawiony poniżej:

$$y_t = x_{t-j} \quad (2.14)$$

gdzie:

y_t – wartość zmiennej prognozowanej w okresie t ,

x_{t-j} – obserwacja oddalona o j okresów,

n – ilość poprzedzających wartości wykorzystanych w modelu średniej ruchomej.

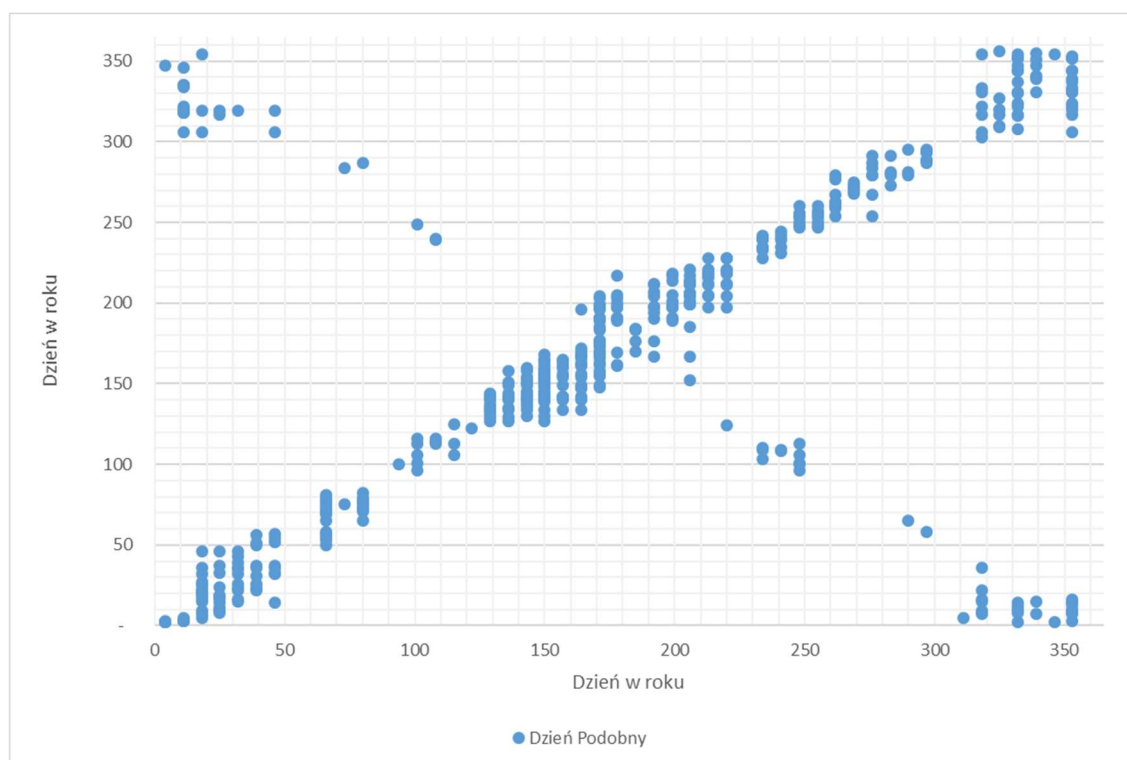
Proste metody, takie jak średnia ruchoma i metoda naiwna, mogą nie zapewniać wystarczająco dobrych rezultatów w bardziej złożonych sytuacjach, zwłaszcza w obecności trendów lub sezonowości. Z tego powodu są one często używane jako punkty odniesienia dla bardziej zaawansowanych modeli, takich jak ARIMA, modele wygładzania wykładniczego czy sieci neuronowe. W literaturze [65] często podkreśla się, że proste metody są użyteczne do wstępnej analizy danych i mogą służyć jako benchmark dla oceny skuteczności bardziej skomplikowanych modeli.

2.4.4 Metoda dnia podobnego

W literaturze naukowej istnieje pojęcie prognozowania metodą dnia podobnego (ang. similar day method), które jest stosowane w kontekście prognozowania zapotrzebowania na energię elektryczną [129]. Metoda ta polega na wyszukiwaniu historycznych dni o podobnych warunkach (np. meteorologicznych, kalendarzowych, dni tygodnia, świąt, specyficznych wzorcach zużycia) do dnia, na który ma być przygotowana prognoza [28, 29]. Metoda dnia podobnego polega na wyznaczeniu wartości prognozowanej równej zaobserwowanej, historycznej wartości w dniu o zbliżonych charakterystykach. Użyteczną wersją tej metody jest metoda polegająca na wybraniu opóźnionej o tydzień obserwacji. Procedura taka ma kilka zasadniczych i oczywistych wad. Po pierwsze, nie uwzględnia wpływu zmiennych pogodowych, a po drugie, przypisywanie dniom ustawowo wolnym od pracy wartości z odpowiedniego dnia tygodnia poprzedniego powodować może duże błędy prognoz. Alternatywą pozostaje przeszukiwanie obserwacji historycznych i wybór najbardziej podobnego, wg ustalonych kryteriów, dnia, dla którego sporządzana jest prognoza. Dodatkową kwestią wartą rozważenia jest długość okresu przeszukiwania. Ze względu na to, że niemożliwe jest stwierdzenie z całą pewnością, która z wersji metody dnia podobnego jest najlepsza, dlatego rozważonych zostało kilka jej wersji.

Pierwsza najprostsza wersja, czyli metoda naiwna, polegała na wyborze wartości opóźnionej o tydzień względem okresu prognozy [127]. Drugim analizowanym wariantem było wybieranie najbardziej podobnej godziny w okresie roku. Najbardziej porównywalna do analizowanej godziny musiała przypadać na ten sam rodzaj dnia (roboczy, sobota, niedziela, dzień ustawowo wolny) oraz mieć podobne charakterystyki pogodowe (temperatura powietrza i natężenie promieniowania słonecznego). Przeszukiwany okres danych wynika z obserwowanej tendencji wzrostowej w zapotrzebowaniu na energię elektryczną w zimie, spadające zapotrzebowanie spowodowane generacją PV oraz migracją klientów do innego sprzedawcy po zakończeniu obowiązywania kontraktu. Selekcja historycznej obserwacji o zbliżonych charakterystykach na podstawie całej próby może teoretycznie doprowadzić do wybrania obserwacji sprzed kilkunastu lat i z okresu o odwrotnym stanie koniunktury. Oznacza to, że jednym z kryteriów doboru najbardziej podobnej obserwacji powinno być podobieństwo fazy cyklu koniunkturalnego.

W przeprowadzonym badaniu szukano dni, które wykazują wysoką korelację przekraczającą 98%. Dni te uszeregowano według kolejności w od początku roku.



Rys. 2.6. Podobieństwa dni pod kątem zapotrzebowania na energię w okresie pełnego roku kalendarzowego

Fig. 2.6. Similarities between days in terms of energy demand during a full calendar year

Wykres 2.6 pokazuje, że dni o podobnej charakterystyce i przebiegu zazwyczaj znajdują się w niewielkiej odległości od siebie. Wyjątkiem jest tutaj początek i koniec roku, gdzie zazwyczaj te dni charakteryzuje zmniejszone zapotrzebowanie na energię elektryczną. Badania korelacji pomiędzy wykazało, że można wyszczególnić 4 kategorie dni tygodnia. Pierwsza i druga to sobota oraz niedziela. Te dni wykazują prawie stuprocentowe podobieństwo do analogicznych typów dni tygodnia, czyli odpowiednio

soboty i niedzieli. Trzecia kategoria to poniedziałek – w większości przypadków odpowiada temu samemu typowi dnia (poniedziałkowi). Ostatnia kategoria to dni robocze od wtorku do piątku. Ten typ dnia charakteryzuje się najmniejszą korelacją z analogicznym typem dnia tygodnia.

Tab. 2.2. Zestawienie wyników podobieństwa dni tygodnia, używane w metodzie dnia podobnego

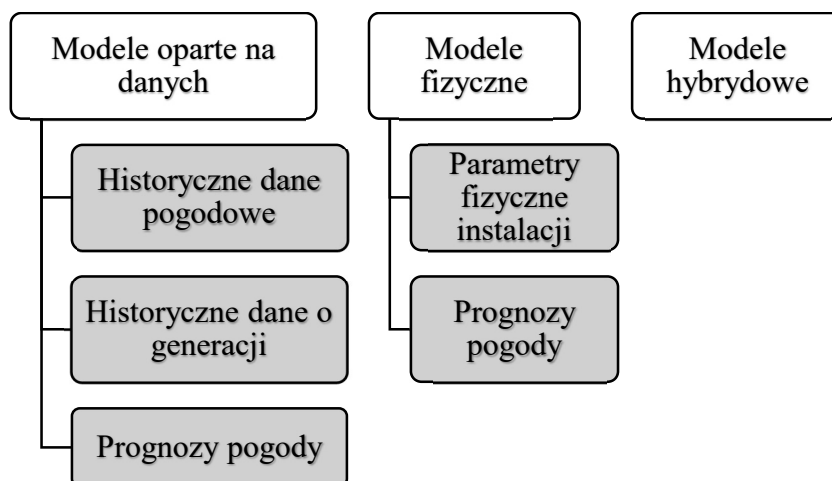
Table 2.2. Summary of similarity results for days of the week used in the similar day method

Dzień tygodnia	Dzień podobny						
	Poniedziałek	Wtorek	Środa	Czwartek	Piątek	Sobota	Niedziela
Poniedziałek	56%	14%	9%	12%	9%		
Wtorek	6%	24%	29%	28%	13%		
Środa	6%	22%	23%	31%	18%		
Czwartek	9%	25%	23%	22%	21%		
Piątek	8%	19%	23%	27%	24%		
Sobota						100%	
Niedziela	4%						96%

W tabeli 2.2. zostały przedstawione wyniki podobieństwa dni tygodnia, używane w metodzie dnia podobnego.

2.4.5 Modele prognostyczne generacji fotowoltaicznej

Istnieją różne modele, które mogą być użyte do prognozowania generacji z instalacji fotowoltaicznych. Najczęściej stosowane są modele oparte na danych [71, 72, 73], modele oparte na właściwościach fizycznych instalacji fotowoltaicznej [74, 75] oraz modele hybrydowe [9]. Powyższą klasyfikację przedstawia schemat na rysunku 2.7.




Rys. 2.7. Podział metod prognozowania generacji PV [9]

Fig. 2.7. Classification of PV generation forecasting methods [9]

Regresja liniowa może być używana do prognozowania generacji energii z paneli fotowoltaicznych, ale nie zawsze jest to najlepsze rozwiązanie. Regresja liniowa opiera się na założeniu, że istnieje liniowa zależność między dwoma lub więcej niż dwoma zmiennymi i jest skuteczna, gdy ta zależność rzeczywiście występuje. Zależność taka możliwa jest dzięki zastosowaniu zabiegu, polegającego na podzieleniu danych na część

odpowiadające pozycji słońca na niebie. Wykorzystuje się do tego parametr azymutu (tj. odchylenie od kierunku południowego) oraz parametr wysokości słońca nad horyzontem, który jest zależny od pory roku.



Rys. 2.8. Graficzna prezentacja sprawności generacji PV na obszarze, tzw. krzywa nasłonecznienia [37]

Fig. 2.8. Graphical presentation of PV generation efficiency in the area, the so-called solar radiation curve [37]

Przykład krzywej nasłonecznienia został przedstawiony na powyższym wykresie – 2.8. Metoda została dokładniej opisana w literaturze [37]. W przypadku prognozowania generacji energii z paneli fotowoltaicznych, zależność między ilością produkowanej energii a czynnikami zewnętrznymi, takimi jak natężenie promieniowania słonecznego, może być bardziej skomplikowana niż liniowa. W takim przypadku modele bardziej zaawansowane, takie jak sieci neuronowe, są skuteczniejsze, ponieważ są elastyczniejsze i pozwalają na uczenie się skomplikowanych zależności. W każdym przypadku ważne jest, aby dokładnie zwalidować model i ocenić jego dokładność, aby upewnić się, że jest on odpowiedni do prognozowania wybranej wielkości. Dla efektywnego wykorzystania modeli prognostycznych, w tym sieci neuronowych, kluczowe są kompletność i struktura danych. W przypadku prognozowania generacji energii z paneli fotowoltaicznych, dane powinny zawierać informacje o czynnikach, które mają wpływ na produkcję energii. Głównie jest to natężenie promieniowania słonecznego, temperatura powietrza, wilgotność powietrza, a także azymut i wysokość słońca nad horyzontem. Dane do nauki modelu powinny być reprezentowane jako szeregi czasowe, gdzie każdy punkt danych odpowiada konkretnemu okresowi i zawiera wartości dla wszystkich czynników wpływających na produkcję energii. W przypadku sieci neuronowej, dane powinny być znormalizowane, aby zachować jednolitą skalę dla wszystkich czynników. Dane powinny być bez błędów i braków, ponieważ nawet małe błędy w danych mogą mieć duży wpływ na dokładność prognoz. W razie potrzeby można również usunąć wartości odstające i uzupełnić brakujące wartości, aby zapewnić jak najlepszą jakość danych wejściowych do modelu.

Spółka obrotu wykorzystuje następujące algorytmy do prognozowania zapotrzebowania na energię elektryczną:

- metodę dnia podobnego,
- modele boxa Jenkinsa – ARIMA,
- modele wygładzania wykładniczego – ETS, STL,
- modele regresji wielokrotnej,
- modele uczenia maszynowego – drzewa regresji ze wzmocnieniem.

W zakresie prognozowania generacji fotowoltaicznej lub oddania energii elektrycznej do sieci dystrybucyjnej spółka sprzedażowa wykorzystuje:

- metodę dnia podobnego,
- modele uczenia maszynowego – drzewa regresji ze wzmocnieniem,
- metodę krzywej nasłonecznienia [41].

2.5 Budowa modelu

Budowa modelu prognostycznego, szczególnie w kontekście prognozowania generacji mikroinstalacji PV lub autokonsumpcji energii elektrycznej przez prosumentów, obejmuje kompleksowy zestaw etapów. Każdy z tych etapów ma kluczowe znaczenie dla zapewnienia dokładności i niezawodności modelu [38]. Etap pierwszy obejmuje zbieranie danych:

- historycznych, dotyczących wytwarzania i zużycia energii elektrycznej,
- historycznych, meteorologicznych,
- dotyczących mocy zainstalowana mikroinstalacji PV, planowanego rocznego zapotrzebowania odbiorców.

Etap drugi obejmuje przygotowanie danych, w tym m.in.:

- obróbkę, tj. oczyszczanie danych z szumów i błędów – agregacja danych w odpowiednie interwały czasowe,
- usuwanie odstających wartości (outliers) – identyfikacja i usuwanie wartości nietypowych, które mogą zaburzyć trening modelu,
- uzupełnianie brakujących wartości (missing data) – możliwe jest stosowanie takich metod, jak interpolacja, imputacja medianą lub średnią,
- normalizację/standaryzację danych, polegające na skalowaniu danych do określonego zakresu, co jest szczególnie ważne dla algorytmów wrażliwych na skalę danych (np. sieci neuronowe).

Etap trzeci to wybór modelu. Spośród szerokiej gamy modeli i technik prognostycznych należy wybrać model, który najlepiej odwzorowuje badane zjawisko. Etap czwarty to trening modelu na zbiorze danych treningowych. Etap ten obejmuje kolejne podpunkty:

- a) podział danych na zbiory treningowy i testowy, zazwyczaj w stosunku 70-80% danych do treningu i 20-30% do testów [79],
- b) optymalizacja parametrów, w tym dostosowywanie hiperparametrów modelu za pomocą takich metod, jak grid search czy random search,

- c) wykorzystanie technik zapobiegających nadmiernemu dopasowaniu (overfitting), np. za pomocą regularyzacji lub metodą drop-out w sieciach neuronowych.

Piąty etap obejmuje walidację wytrenowanych modeli, aby lepiej ocenić stabilność i wydajność modelu. Metody walidacji krzyżowej (cross-validation) to np. k-fold cross-validation. Na tym etapie dokonuje się porównania prognoz z rzeczywistymi wartościami. Do oceny możliwe jest użycie metryk, takich jak MAE (Mean Absolute Error), RMSE (Root Mean Squared Error), MAPE (Mean Absolute Percentage Error), które zostaną wyjaśnione w dalszej części. Istotną częścią walidacji jest analiza reszt (residuals), gdzie należy sprawdzić, czy reszty są losowo rozłożone i nie wykazują ani wzorców, ani autokorelacji.

Szósty i ostatni etap obejmuje implementację wybranych modeli. Na tym etapie model jest używany na aktualnych danych. Należy umożliwić integrację modelu z systemem zbierania i analizowania danych w czasie rzeczywistym. Etap ten jest ciągły, co oznacza, że należy regularnie monitorować wydajności modelu oraz sprawdzać dokładność prognoz i w razie potrzeby dokonać aktualizacji modelu.

Proces budowy modelu prognostycznego jest iteracyjny i może wymagać kilku cykli treningu i walidacji, aby uzyskać wystarczająco dokładne prognozy. Często wraca się do wcześniejszych etapów, aby poprawić jakość danych, modelu czy jego dostosowanie do zmieniających się warunków [39].

2.6 Dobór zmiennych objaśniających

W badaniach wykorzystywane są historyczne dane dotyczące zapotrzebowania na energię elektryczną oraz wskaźniki, takie jak np. historyczne dane pogodowe. Jak podaje literatura, zmienne objaśniające mogą zostać wybrane metodą eliminacji [1]. Do wyboru istotnych zmiennych objaśniających użyty został algorytm stepwisefit (funkcja w Matlabie). Jest to metoda używana do wybierania predyktorów w modelach regresji. Badanie istotności poszczególnych współczynników równania regresji polega na weryfikacji hipotezy zerowej, stwierdzającej brak korelacji między badaną zmienną prognozowaną Y a zmienną wyjaśniającą X wobec hipotezy alternatywnej, zaprzeczającej stwierdzenie; można to zapisać w następujący sposób:

$H_0: \rho=0$, brak liniowego związku

$H_1: \rho \neq 0$ istnieje liniowy związek

Proces ten polega na iteracyjnym dodawaniu lub usuwaniu zmiennych wejściowych na podstawie ich statystycznej istotności. Algorytm zaczyna od modelu pustego (bez predyktorów) lub pełnego (ze wszystkimi predyktorami). Następnie krokowo testuje, czy dodanie lub usunięcie predyktora poprawia model. Używa do tego kryteriów takich jak wartość pvalue, statystyka F czy kryterium informacyjne Akaike'a (AIC). Algorytm dodaje predyktor, jeśli jego wartość pvalue jest mniejsza od ustawionego progu (domyślnie 0,05). Algorytm usuwa predyktor, jeśli jego wartość p przekracza ustawiony próg (domyślnie 0,10). Proces ten jest kontynuowany, dopóki nie

można ani dodać, ani usunąć żadnego predyktora, co oznacza, że model osiągnął optymalny zestaw predyktorów. Końcowym wynikiem jest model regresji, zawierający tylko te predyktory, które istotnie wpływają na zmienną zależną, co prowadzi do uproszczenia modelu i poprawy jego interpretowalności. Więcej informacji o metodzie można znaleźć w literaturze [40]. Jako zmienne objaśniające wybiera się zmienne meteorologiczne i kalendarzowe, co jest powszechną praktyką w prognozowaniu obciążenia energią elektryczną. Badana spółka sprzedażowa zmienne pogodowe pozyskuje od komercyjnego dostawcy. Możliwe jest również niekomercyjne uzyskanie większej liczby parametrów meteorologicznych zlokalizowanych na obszarze Polski z IMGW lub od dostawców niekomercyjnych.

Dane meteorologiczne najczęściej składają się z pomiarów temperatury, zachmurzenia i siły wiatru. Temperatura jest wyrażana w stopniach Celsjusza, zachmurzenie to wielkość zachmurzenia, mierzona w oktanach, a wiatr mierzony jest na wysokości 10 m nad ziemią i wyrażany w metrach na sekundę. Stacje pogodowe są nierównomiernie rozmieszczone na obszarze Polski. Dane pogodowe są dostępne w tym samym zakresie, co zużycie energii elektrycznej, z godziną rozdzielczością czasową. Temperatura jest silnie skorelowana z obciążeniem energią elektryczną i ma różny wpływ na zimne i gorące okresy. Obydwa wzorce wynikają ze stosowania w Polsce elektrycznych systemów ogrzewania i klimatyzacji, które zużywają dużo energii elektrycznej. Aby wygenerować zlokalizowane zbiory danych, każda podstacja i jej najbliższa stacja pogodowa są parowane, tworząc specyficzne dla podstacji zbiory danych z lokalnymi danymi pogodowymi.

2.7 Metryki używane do oceny modeli

Dobór odpowiedniego wskaźnika ocen prognoz generacji fotowoltaicznej zależy od specyficznych potrzeb użytkownika. Generalnie do potrzeb optymalizacji prognoz pod kątem handlu energią elektryczną, najważniejsza jest minimalizacja odchyłek prognoz. Najlepszy wskaźnik ocen prognoz generacji fotowoltaicznej to taki, który jest najdokładniejszy i wiarygodny. Wskaźniki te są zazwyczaj obliczane na podstawie danych historycznych i do oceny dokładności prognoz wykorzystują różne metody statystyczne. W niniejszej pracy zastosowane zostały uniwersalne wskaźniki, tj.:

- AE – suma odchylenia bezwzględnego, opisana wzorem:

$$AE = \sum_{i=1}^n |y_i - y'_i| \quad (2.15)$$

- MAE – średnie odchylenie bezwzględne:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (2.16)$$

- R^2 – współczynnik determinacji:

$$R^2 = 1 - \frac{\sum_{i=1}^n |y_i - y'_i|^2}{\sum_{i=1}^n |y_i - \bar{y}_i|^2} \quad (2.17)$$

- RMSE – pierwiastek ze średniej arytmetyczna kwadratów błędów:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (2.18)$$

gdzie:

n – liczba obserwacji,

y_i – rzeczywiste wartości,


y'_i – prognozowane wartości,

\bar{y}_i – średnia wartość rzeczywistych danych.

3 CZYNNIKI WPLYWAJĄCE NA JAKOŚĆ PROGNOZ

3.1 Źródła fotowoltaiczne

Moc zainstalowana w instalacjach PV klientów spółki obrotu wzrosła z 165 MW w 2019 roku do ponad 3 300 MW w 2023 roku, co przedstawiono na rysunku 3.1. Oznacza to wzrost o ponad 2000% w ciągu zaledwie 4 lat. Szczególnie imponujący był wzrost w latach 2021-2022, kiedy to instalowano rocznie ponad 1 GW mocy PV.



Rys. 3.1. Przyrost mocy zainstalowanej w mikroinstalacjach w latach od 2016 do 2024, w podziale na obszary


Fig. 3.1. Increase in installed capacity in micro-installations in the years 2016 to 2024, divided into areas

Istnieje kilka czynników, które przyczyniły się do dynamicznego wzrostu rynku PV w Polsce, w latach 2019-2022. Były to między innymi:

- Ustawa o odnawialnych źródłach energii, która wprowadziła wiele korzystnych regulacji dla rozwoju PV.
- Dostępne programy dofinansowania instalacji PV, zarówno dla gospodarstw domowych, jak i firm.
- Spadek ceny paneli PV, co czyni je dostępniejszymi dla inwestorów.
- Wzrost cen surowców energetycznych oraz praw do emisji energii elektrycznej.
- Wzrost świadomości ekologicznej użytkowników energii elektrycznej.

Rynek PV w Polsce, według większości projekcji, w najbliższych latach będzie nadal dynamicznie rosnąć. Według różnych prognoz, moc zainstalowana w instalacjach PV w Polsce może osiągnąć 10 GW do 2025 roku i 20 GW do 2030 roku.

Wpływ generacji fotowoltaicznej na profil zapotrzebowania jest bardzo istotny. Zostało to przedstawione na rysunku 3.2, gdzie porównano zapotrzebowanie z wybranych dni roboczych na przełomie marca i kwietnia 2022 roku.




Rys. 3.2. Wpływ generacji fotowoltaicznej prosumentów na profil zapotrzebowania netto, na wybranym obszarze

Fig. 3.2. Impact of prosumers' photovoltaic generation on the net demand profile in the selected area

Charakterystyczny spadek zapotrzebowania („duck curve”) 23 marca i 13 kwietnia spowodowany jest generacją prosumenckich instalacji fotowoltaicznych. Dane z 1 kwietnia przedstawiają z kolei „stary” profil zapotrzebowania, gdy nie było generacji fotowoltaicznej. Duck curve to termin używany do opisu charakterystycznego kształtu wykresu zapotrzebowania na energię w systemie energetycznym, w regionach o dużym udziale energii odnawialnej, zwłaszcza fotowoltaiki. Kształt tej krzywej przypomina sylwetkę kaczki, stąd jej nazwa [30]. W godzinach porannych (kiedy produkcja energii słonecznej jest jeszcze niska) system musi dostarczyć energię na potrzeby użytkowników. W południe, kiedy panele fotowoltaiczne generują dużą ilość energii, zapotrzebowanie na energię z sieci gwałtownie spada. W skrajnych przypadkach może to prowadzić do sytuacji, w której produkcja energii przewyższa zapotrzebowanie. Po zmroku produkcja energii z fotowoltaiki spada do zera, a użytkownicy muszą ponownie korzystać z energii z sieci, co prowadzi do gwałtownego wzrostu zapotrzebowania w godzinach wieczornych. Wiele badań naukowych jest poświęconych wpływowi prosumentów oraz decentralizacji źródeł energii na system elektroenergetyczny. Bada są między innymi ograniczenia systemów energetycznych z dużym udziałem PV, podkreślając potrzebę rozwoju technologii magazynowania energii w kontekście duck curve [31, 32].

Profil generacji prosumentów, w przypadku braku danych rzeczywistych generacji PV, można odwzorować przez różnicę profilu zapotrzebowania brutto oraz netto.



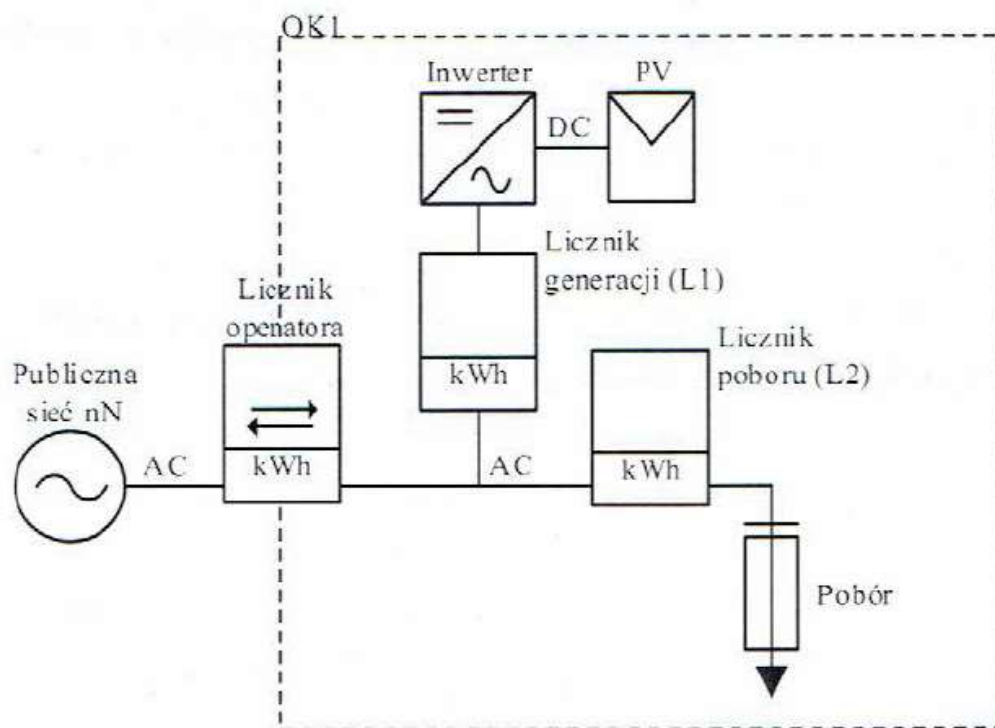
Rys. 3.3. Szacunkowa generacja PV prosumentów, wyznaczona z różnicy profilu brutto i netto w wybranych dniach 2022 roku na wybranym obszarze

Fig. 3.3. Estimated PV generation of prosumers, determined from the difference between the gross and net profiles on selected days in 2022 in the selected area

Metodologia generacji profilu brutto zostanie przedstawiona w dalszej części pracy. Na wykresie 3.3 pokazano profil generacji PV prosumentów z analogicznych dni (23 marca 2022, 1 i 13 kwietnia 2022), wyznaczone z różnicy profilu brutto oraz profilu netto.

3.2 Prosumenci – generacja „za licznikiem”

Instalacje fotowoltaiczne prosumentów są rozproszone na dużym obszarze, gdzie panują zmienne warunki atmosferyczne. Liczniki energii elektrycznej, montowane przez OSD, nie mierzą rzeczywistej generacji instalacji fotowoltaicznych zainstalowanych prosumentów. Typowy schemat pomiarowy mikroinstalacji PV został przedstawiony na wykresie 3.4.



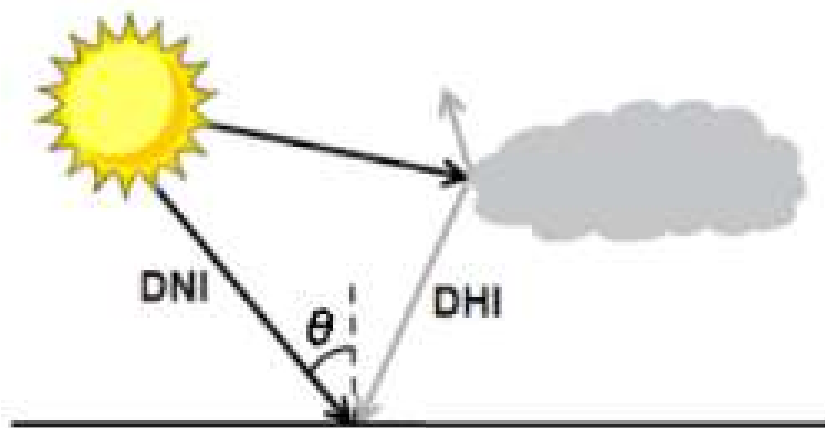
Rys. 3.4. Typowa konfiguracja pomiarowa mikroinstalacji [3]

Fig. 3.4. Typical measurement configuration of a micro-installation [3]

Spółka obrotu nie posiada dostępu do danych rzeczywistych o generacji energii elektrycznej z ww. instalacji. Dane, którymi spółka dysponuje do prognozowania zapotrzebowania to dane o oddaniu energii elektrycznej do sieci dystrybucyjnej. Zaznaczyć tutaj należy, że aktualne uregulowania prawne nie umożliwiają operatorom systemu elektroenergetycznego (OSP i OSD) dostępu do danych o aktualnej generacji i zużyciu energii elektrycznej przez prosumentów („za licznikiem”), co powoduje trudności w prognozowaniu warunków pracy systemu elektroenergetycznego, jak również jego rozwoju w kierunku zapewnienia niezbędnych usług elastyczności. URE jako organ regulacyjny rekomenduje odpowiednie zmiany prawne w zakresie uzyskania przez operatorów systemu dostępu do ww. danych. Z przedstawionego powyżej schematu (rys. 3.4) wynika, że zazwyczaj u prosumentów istnieje licznik energii elektrycznej wygenerowanej przez mikroinstalację. Jednak licznik ten jest montowany na koszt właściciela instalacji, a dane z tych „podliczników” nie są pozyskiwane przez operatorów systemów dystrybucyjnych. Spółka obrotu ma tylko dane o ilości energii elektrycznej pobranej oraz wprowadzonej do sieci przez odbiorcę. Wszystko, co dzieje się w obrębie instalacji wewnętrznej nie jest monitorowane przez spółkę obrotu. W przypadku zainstalowania kolejnego źródła lub magazynu energii albo samochodu elektrycznego, profil takiego odbiorcy ulegnie dużej zmianie. Powyższe zmiany wymagają monitorowania oraz analizy ich wpływu na profil zapotrzebowania. Prognozowanie zapotrzebowania na energię elektryczną jest mocno utrudnione bez danych o zainstalowanej mocy w fotowoltaice albo innym źródle wytwórczym bądź też w magazynie energii.

3.3 Promieniowanie słoneczne

Promieniowanie słoneczne ma największy wpływ na generację fotowoltaiczną spośród wszystkich analizowanych zmiennych objaśniających. Nie jest łatwo znaleźć dobre prognozy tego parametru, dlatego jednym z zadań było poszukiwanie prognozy w horyzoncie czasowym, odpowiadającym horyzontowi przygotowywaniu prognoz zapotrzebowania na energię elektryczną.



Rys. 3.5. Równanie na obliczenie GHI, używając DNI i DHI [56]

Fig. 3.5. Equation for calculating GHI using DNI and DHI [56]

Promieniowanie słoneczne GHI to promieniowanie całkowite na powierzchnię poziomą. Jest sumą promieniowania bezpośredniego i rozproszonego na płaszczyźnie poziomej [58], co przedstawiono na rysunku 3.5. Zależność pomiędzy GHI a DNI i DHI przedstawia wzór 3.1:

$$GHI = DNI * \cos(\theta) + DHI \quad (3.1)$$

gdzie:

GHI – globalne promieniowanie poziome

DNI – bezpośrednie, normalne natężenie promieniowanie,


DHI – rozproszone natężenie promieniowania poziomego.

DNI to promieniowanie, które pada bezpośrednio na powierzchnię ustawioną prostopadle do kierunku promieniowania słonecznego. DHI to promieniowanie docierające do powierzchni poziomej z atmosfery, ale bez promieniowania bezpośredniego, pochodzące od chmur lub cząstek atmosferycznych [57]. GHI jest najczęściej używanym parametrem do obliczania generacji PV w przypadku płaskich, nieruchomych paneli ustawionych pod określonym kątem nachylenia. GHI zawiera zarówno składnik promieniowania bezpośredniego, jak i rozproszonego, co czyni go dobrym wskaźnikiem dla systemów fotowoltaicznych o stałym ustawieniu. W większości przypadków domowe instalacje PV korzystają właśnie z takiego układu, gdzie kluczowe jest, ile energii dociera do paneli na powierzchni poziomej. GHI będzie zatem łatwiejszy do zastosowania, ponieważ wymaga mniej obliczeń i jest bezpośrednio dostępny w wielu zbiorach danych meteorologicznych.

Z kolei DNI i DHI są bardziej precyzyjne w przypadku systemów, które są ruchome lub wyposażone w system śledzenia słońca, czyli podążają za ruchem słońca, aby maksymalizować ekspozycję na bezpośrednie promieniowanie słoneczne. DNI jest kluczowy dla takich systemów, ponieważ panele są ustawione prostopadle do promieniowania słonecznego i generacja PV w dużej mierze zależy od promieniowania bezpośredniego. Zatem w przypadku bardziej zaawansowanych analiz lub w sytuacji, gdy wymagane jest modelowanie wpływu warunków atmosferycznych na generację PV (np. w kontekście wpływu chmur na promieniowanie rozproszone), użycie DNI i DHI pozwala na bardziej szczegółowe obliczenia, ponieważ oddziela promieniowanie bezpośrednie od rozproszonego.

3.4 Pompy ciepła

Pompy ciepła, służące do ogrzewania pomieszczeń i przygotowania ciepłej wody użytkowej, dostosowują temperaturę czynnika grzewczego, wykorzystując tzw. krzywą grzewczą. Ma to swoje odbicie w zwiększonym zużyciu energii elektrycznej w okresach niskich temperatur. Duża liczba PC pracujących jednocześnie może powodować przeciążenia sieci elektroenergetycznej. Zjawisko to uwidacznia się szczególnie w okresie temperatur poniżej -15°C . Jest to wartość temperatury, od której w większość pomp typu powietrze woda może zostać uruchomiona grzałka elektryczna wspomagająca pracę pompy. Niewątpliwie pozytywnymi aspektami zastępowania tradycyjnych źródeł ciepła (kotły węglowe i gazowe) są poprawa jakości powietrza oraz zmniejszenia emisji CO_2 . Liczba zainstalowanych pomp ciepła w Polsce wzrosła dynamicznie w latach 2021-2023, co przedstawia wykres na rysunku 3.6.




Rys. 3.6. Przyrost pomp ciepła w Polsce w latach od 2010 do 2022 [5]

Fig. 3.6. Growth of heat pumps in Poland from 2010 to 2022 [5]

Według danych Polskiego Stowarzyszenia Pomp Ciepła, w 2022 roku, w Polsce zainstalowano ponad 100 tys. PC. Oznacza to wzrost o 70% w stosunku do 2021 roku. Według danych z Centralnej Ewidencji Emisyjności Budynków (CEEB), na koniec 2023 roku w Polsce zgłoszonych było ponad 350 tys. pomp ciepła, służących do ogrzewania budynków mieszkalnych [5]. W ramach programu Czyste Powietrze można otrzymać


dotacje na przeprowadzenie niezbędnych prac termomodernizacyjnych, a także wymianę starych kotłów na paliwo stałe na nowoczesne źródła ciepła. Prawdziwy boom na te ekologiczne urządzenia grzewcze nastąpił w maju 2022 roku. Było to spowodowane ogłoszeniem pakietu „REPowerEU”, stanowiącego energetyczną odpowiedź na napaść Rosji na Ukrainę i zapowiadającego szybkie odejście od stosowania paliw kopalnych w budynkach. Równocześnie nastąpił wówczas drastyczny wzrost udziału wniosków o dofinansowanie do pomp ciepła z „Czystego Powietrza”. Jak można zauważyć na poniższym wykresie (rys. 3.7), jeszcze w styczniu 2022 roku ogólna liczba wniosków na wymianę źródeł ciepła na pompę ciepła wynosiła zaledwie 28%, a już w grudniu 63%:



Rys. 3.7. Udział procentowy poszczególnych technologii we wnioskach programu „Czyste powietrze” [6]

Fig. 3.7. Percentage share of individual technologies in the “Clean Air” program applications [6]

Jak pokazuje dalszy przebieg wykresu, od początku 2023 roku udział pomp ciepła zaczął spadać na rzecz kotłów na biomasę. Oczekuje się jednak, że liczba pomp ciepła w Polsce, w najbliższych latach będzie nadal rosła. Według różnych prognoz do 2030 roku w Polsce może być zainstalowanych nawet milion pomp ciepła. Tak duży udział PC generuje znaczące obciążenie sieci energetycznej i nie może być pominięty w algorytmach prognozowania zapotrzebowania na energię elektryczną. Wykres z rysunku 3.8 przedstawia zależność pomiędzy dobowym zapotrzebowaniem na energię elektryczną na wybranym obszarze (w MWh) a średnią dobową temperaturą powietrza (w stopniach Celsjusza). Można zakładać, że wraz ze wzrostem udziału ogrzewania elektrycznego jeszcze bardziej widoczna będzie ta zależność.



Rys. 3.8. Zależność pomiędzy dobowym zapotrzebowaniem na energię elektryczną a temperaturą powietrza na wybranym obszarze

Fig. 3.8. Relationship between daily electricity demand and air temperature in the selected area

Oś pionowa przedstawia zapotrzebowanie na energię elektryczną, a oś pozioma temperaturę. Wraz ze wzrostem temperatury zapotrzebowanie na energię spada, co wskazuje na zależność odwrotnie proporcjonalną. Tego typu zależność jest dobrze potwierdzona w literaturze naukowej [25, 26, 27]. Wzrost temperatury może powodować spadek zapotrzebowania na energię w okresach chłodniejszych, kiedy jest mniejsze wykorzystanie urządzeń grzewczych. Z kolei w okresach cieplejszych wyższe temperatury mogą zwiększać zapotrzebowanie na energię związaną z klimatyzacją, chociaż to zależy od konkretnego klimatu i rodzaju odbiorców (np. przemysłowych czy indywidualnych).

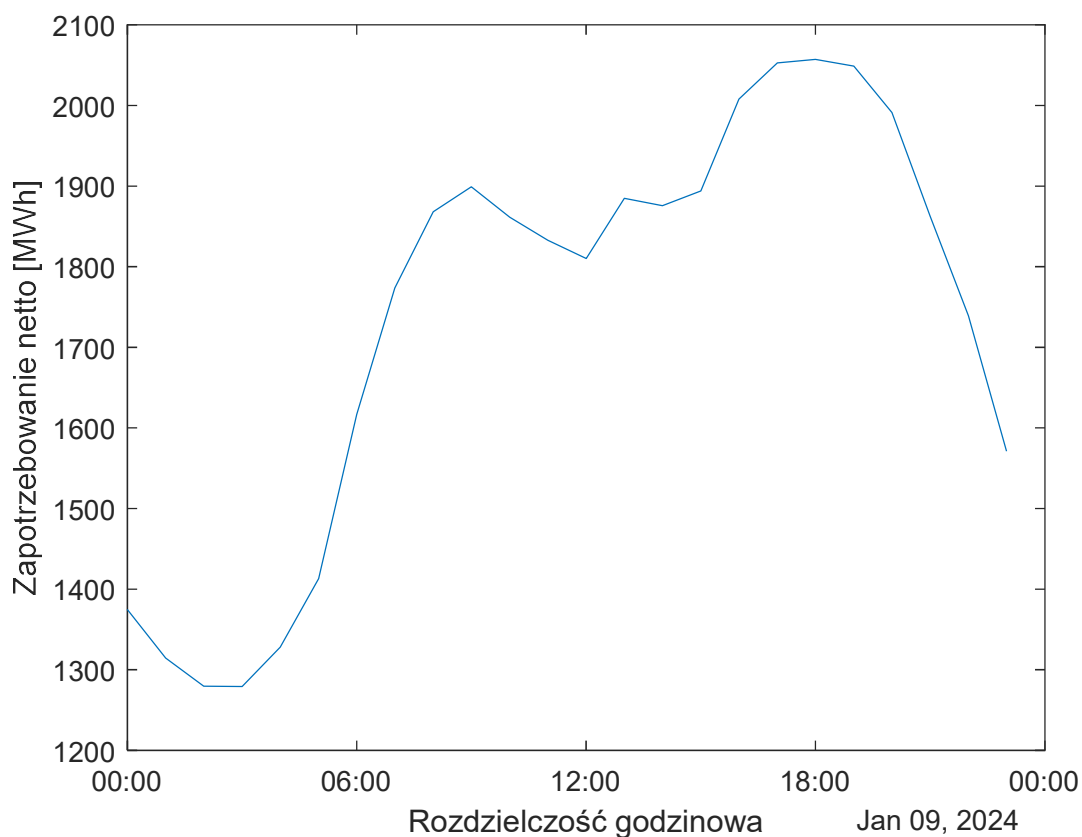
3.5 Sezonowość

Skuteczne wykorzystanie możliwości, jakie daje rynek terminowy oraz możliwość poniesienia strat, wynikających z przekontraktowania (gdy zakupiono więcej energii niż potrzeba) lub niedokontraktowania (gdy zakupiono mniej energii niż potrzeba), wymaga dokładnych prognoz w interwale godzinowym, a od 14 czerwca 2024 roku w interwale 15-minutowym. Kierowanie się jedynie doświadczeniem i intuicją osoby sporządzającej prognozę jest zawodne i powoduje losowe odchylenia prognozy od danych rzeczywistych. Dlatego podstawą do przygotowania prognozy powinna być prognoza modelowa. Dopiero tak wyliczoną prognozę, popartą sprawdzonymi rozwiązaniami informatycznymi, opartymi na gruntownej znajomości metod statystycznych

i zaawansowanych technik obliczeniowych, można przedstawić do dalszej oceny ekspertowi. Zapotrzebowanie na energię elektryczną jest złożonym procesem stochastycznym, charakteryzującym się między innymi sezonowością (w obrębie roku), okresowością (tygodniową) i quasi-okresowością (dobową). Istotny wpływ na zapotrzebowanie mają warunki atmosferyczne (temperatura, natężenie promieniowania słonecznego lub zachmurzenie, prędkość wiatru). Dodatkowe zakłócenia wprowadzają dni świąteczne oraz wydarzenia natury społecznej. Dane przedstawione na poniższych wykresach (rys. 3.9, 3.10, 3.11) przedstawiają szereg czasowy danych rzeczywistych zapotrzebowania na energię elektryczną (ER), z uwzględnieniem korekt dokonywanych przez OSD w trybach M+2, M+4, M+15 (M to miesiąc, którego dotyczy korekta danych). Dane są z okresu od 1 stycznia 2016 roku do 31 grudnia 2020 roku.

Zapotrzebowanie na energię elektryczną może być prognozowane przy wykorzystaniu technik wykorzystujących własności szeregów czasowych. Szereg czasowy to ciąg uporządkowanych obserwacji, których dokonuje się w określonych (zwykle stałych) jednostkach czasu. W przypadku zapotrzebowania na energię elektryczną wartości są wyznaczone w godzinowych odstępach czasu. Zapotrzebowanie na energię elektryczną wykazuje kilka sezonowość i okresowość, co oznacza, że cykle powtarzają się z określoną częstotliwością S :


- okresowość dzienna ($S=24$ godzin) – w ciągu dnia zapotrzebowanie ma charakter cykliczny, ze szczytami w godzinach porannych i wieczornych (szczególnie w gospodarstwach domowych), a także spadkami w nocy. Okresowość dobową została przedstawiona na rysunku 3.9.



Rys. 3.9. Dobbwe zapotrzebowanie na energię elektryczną na wybranym obszarze

Fig. 3.9. Daily electricity demand in the selected area


- Okresowość tygodniowa ($S=168$ godzin) – w dni robocze zapotrzebowanie jest zazwyczaj wyższe niż w weekendy, co wynika z intensywności pracy przemysłu i działalności gospodarczej. W niedziele, a także w niektóre dni świąteczne, zapotrzebowanie może być niższe. Okresowość tygodniowa została przedstawiona na rysunku 3.10.



Rys. 3.10. Tygodniowe zapotrzebowanie na energię elektryczną na wybranym obszarze

Fig. 3.10. Weekly electricity demand in the selected area


- Sezonowość roczna ($S=8760$ godzin) – zapotrzebowanie zależy od pór roku. Latem może ono wzrastać ze względu na korzystanie z klimatyzacji, a zimą z powodu ogrzewania elektrycznego. Sezonowość roczna została przedstawiona na rysunku 3.11.



Rys. 3.11. Roczne zapotrzebowanie na energię elektryczną netto na wybranym obszarze

Fig. 3.11. Annual net electricity demand in the selected area

Profil obciążenia jest obrazem zapotrzebowania na energię elektryczną. Można go zdefiniować jako zbiór danych, określających ilość energii elektrycznej planowanej do wprowadzenia lub poboru z sieci, oddzielnie dla poszczególnych okresów (np. dzień, tydzień, miesiąc czy rok). Standaryzacja takiego grafiku może prowadzić do opracowania profilu charakterystycznego dla danego odbiorcy bądź grupy odbiorców, a którego wykorzystanie może być pomocne przy prognozowaniu zapotrzebowania na energię elektryczną. Jednak, jak pokazuje wykres 3.12 przedstawiający szereg w dłuższym horyzoncie czasowym, dane wykazują się coraz większą zmiennością, co szczególnie można zauważyć od 2022 roku. W tym kontekście wykorzystanie tylko danych historycznych do stworzenia profilu zapotrzebowania jest w ocenie autora niewystarczające. Konieczne jest uwzględnienie wpływu generacji fotowoltaicznej na profil zapotrzebowania netto oraz zwiększonego zapotrzebowania na generację ciepła w okresach niskich temperatur.



Rys. 3.12. Zapotrzebowanie na energię elektryczną netto na wybranym obszarze w okresie 9 lat

Fig. 3.12. Net electricity demand in the selected area over a 9-year period

W tabeli 3.1 wyznaczony został procentowy wzrost zapotrzebowania na energię elektryczną w odniesieniu do 2016 roku.

Tab. 3.1. Zmiany procentowe w zapotrzebowaniu na energię elektryczną, na wybranym obszarze

Tab. 3.1. Percentage changes in electricity demand in the selected area

Sezon	Rok	Maksimum	Średnia	Minimum
letni	2016	100%	100%	100%
	2017	105%	108%	125%
	2018	105%	107%	128%
	2019	104%	111%	134%
	2020	108%	108%	135%
	2021	114%	110%	143%
	2022	113%	97%	65%
	2023	111%	87%	20%
	2024	102%	78%	-5%
zimowy	2016	100%	100%	100%
	2017	102%	105%	125%
	2018	99%	107%	125%
	2019	98%	106%	127%
	2020	103%	109%	126%
	2021	113%	113%	126%

	2022	107%	106%	86%
	2023	108%	107%	63%
	2024	112%	98%	28%

W sezonie letnim wzrost zapotrzebowania do 2021 roku (przykładowo średnie wzrosło z 100% w 2016 roku do 110% w 2021 roku) może być częściowo związany ze wzrostem korzystania z klimatyzacji latem, co zwiększa ogólną konsumpcję energii. W tym samym czasie obserwujemy wzrost minimalnego zapotrzebowania (np. 134% w 2019 roku i 143% w 2021 roku), co sugeruje wyraźny wzrost nocnego zużycia. Jednak od 2022 roku widać spadek średniego zapotrzebowania (87% w 2023 roku i 78% w 2024 roku), co może wynikać z rozwoju fotowoltaiki, której produkcja obniża zużycie energii w ciągu dnia. Obniżenie minimum do ujemnych wartości (-5% w 2024 roku) wskazuje na to, że lokalna generacja PV jest w stanie częściowo pokryć zapotrzebowanie w najniższym momencie dobowym.

W zimie wzrost średniego zapotrzebowania do 2021 roku (z 100% w 2016 roku do 113% w 2021 roku) można przypisać rosnącemu udziałowi pomp ciepła, stosowanych do ogrzewania budynków. Jednak w późniejszych latach (2022-2024) obserwujemy stabilizację, a nawet spadek średnich wartości zapotrzebowania (98% w 2024 roku), co może sugerować, że PV zimą także zaczyna mieć zauważalny wpływ, choć nie jest tak wyraźny jak latem. Wartości minimalne w ostatnich latach (2023 – 63% oraz 2024 – 28%) wskazują, że w sprzyjających warunkach nasłonecznienia i temperatury generacja PV w niektórych godzinach pokrywa większą część zapotrzebowania odbiorców na energię elektryczną.

3.6 Inne czynniki wpływające na zmienność zapotrzebowania

Oprócz generacji mikroinstalacji fotowoltaicznych oraz zwiększonego zapotrzebowania przez pompy ciepła w okresach niskich temperatur na zmienność zapotrzebowania wpływają nowe mechanizmy bilansowania systemu elektroenergetycznego, oparte na reakcji odbiorców na sygnały cenowe. Mowa tu o taryfach dynamicznych (zmienność ceny w każdej godzinie doby według notowań na TGE), usługach DSR, a także o zwiększeniu zapotrzebowania. Usługi te są związane z dodatkowymi płatnościami za zrealizowane działania odbiorców, polegające na zmniejszeniu lub zwiększeniu zużycia energii elektrycznej. Mechanizmy te mają istotny wpływ na zapotrzebowanie na energię elektryczną. Wystarczy wspomnieć tu okres pandemii COVID 19, podczas której zapotrzebowanie spadło o ponad 10%, a po okresie lock downu znacząco wzrosło przez pompowanie w gospodarkę wielu środków finansowych oraz stymulowanie jej innymi metodami, w tym np. przez obniżki stóp procentowych. Z powyższych rozważań oraz badań literatury [14, 15, 16, 17, 18, 19, 20] wynika, że prognozy zapotrzebowania na energię elektryczną powinny być zintegrowane z systemami zarządzania popytem, co pozwala na dynamiczniejsze i efektywniejsze zarządzanie siecią energetyczną. Predykcja zapotrzebowania na energię z wykorzystaniem danych pomiarowych wspiera działania mające na celu optymalizację produkcji energii, zarządzanie magazynami energii oraz odpowiednie alokowanie zasobów. Dokładność prognozowania zapotrzebowania na energię elektryczną jest coraz

mniejsza. Głównym powodem jest szybki wzrost rozproszonych mikroinstalacji, pojazdów elektrycznych i reakcji na sygnały cenowe. Do prognozowania obciążeń wprowadza to coraz większą niepewność oraz zwiększa prawdopodobieństwo wystąpienia większych błędów prognozowania [13].

3.7 Agregacja danych odbiorców

Wiele badań wskazuje na rosnącą rolę danych pomiarowych o wysokiej rozdzielczości czasowej, np. dane godzinowe czy – obecnie stosowane w rozliczeniach na rynku bilansującym – dane 15-minutowe. Dane o wysokiej rozdzielczości dostarczają szczegółowych informacji o zachowaniach konsumpcyjnych odbiorców energii, co z kolei poprawia jakość prognoz zapotrzebowania na energię. Jeśli mamy dane w postaci dyskretnych pomiarów mocy $P_i[n]$ dla każdego odbiorcy w rozważanym przedziale czasowym, to suma zapotrzebowania na energię dla wszystkich N odbiorców w okresie t składającym się z M pomiarów (np. co 15 minut, godzinę itd.), będzie:

$$E_{tot} = \sum_{i=1}^N \sum_{n=1}^M P_i[n] \Delta t \quad (3.1)$$

gdzie:

E_{tot} – całkowita energia zużyta przez wszystkich odbiorców w danym okresie,

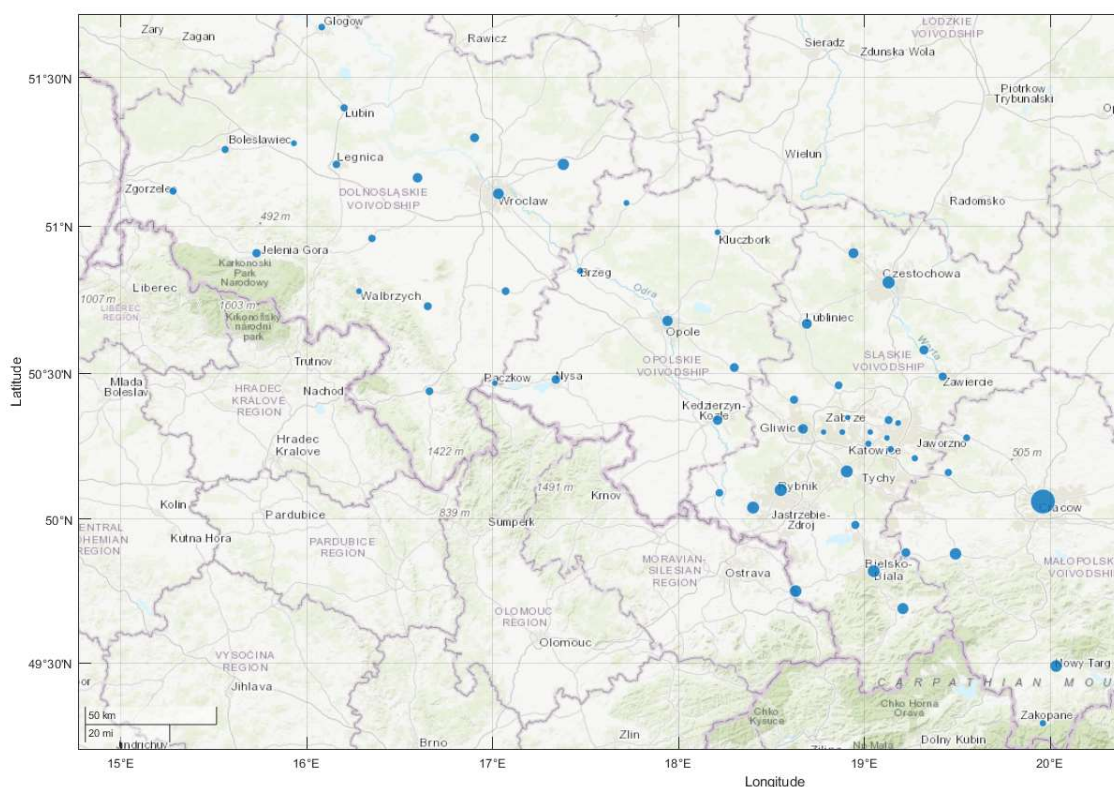
$P_i[n]$ – zmierzona moc i -tego odbiorcy w n -tym przedziale czasowym,

Δt – długość jednego przedziału czasowego (np. 15 minut lub godzina),

M – liczba pomiarów w okresie T .

Wartość $P_i[n]$ może być średnią mocą pobraną przez odbiorcę w danym przedziale czasu. W obu przypadkach otrzymana wartość E_{tot} to całkowita energia zużyta przez wszystkich odbiorców w danym okresie (kwadransie, godzinie). Zastosowanie inteligentnych liczników (smart meters) znacząco zwiększyło dostępność tych danych. Mimo dostępności danych o wysokiej rozdzielczości, nie zawsze jest uzasadnione ich pełne wykorzystanie. Czasami korzystniejsze jest stosowanie agregacji danych pomiarowych. Odbywa się ono na różnych poziomach – od pojedynczych gospodarstw domowych, po całe regiony. Wzorce zużycia energii różnią się w zależności od typu odbiorcy (przemysłowi, komercyjni, indywidualni), a uwzględnienie tego zróżnicowania jest kluczowe dla dokładnych prognoz. Różne profile zużycia wymagają różnych metod modelowania i agregacji, co stanowi wyzwanie dla uniwersalnych rozwiązań predykcyjnych. Kluczowe jest zatem, aby metody agregacji uwzględniały zmienność zużycia energii w poszczególnych segmentach odbiorców. Zastosowanie zaawansowanych metod statystycznych i technik uczenia maszynowego pozwala na precyzyjne prognozowanie zużycia energii, zwłaszcza w przypadkach nieregularnych wzorców zużycia.

Coraz więcej prac skupia się na integracji prognozowania zapotrzebowania na energię z systemami zarządzania popytem, co pozwala na dynamiczniejsze i efektywniejsze zarządzanie siecią energetyczną. Predykcja zapotrzebowania na energię z wykorzystaniem danych pomiarowych wspiera działania mające na celu optymalizację produkcji energii, zarządzanie magazynami energii oraz odpowiednie alokowanie zasobów. Rozwój technologii pomiarowych oraz zaawansowanych metod analitycznych przyczynia się do coraz lepszych prognoz zapotrzebowania na energię. Mimo to, nadal pozostaje wiele wyzwań, zwłaszcza związanych z przetwarzaniem ogromnych ilości danych i radzeniem sobie z ich jakością. Agregacja klientów spółki obrotu jest zorganizowana w dwóch płaszczyznach. Pierwsza agregacja jest zrobiona ze względu na położenie geograficzne odbiorców.

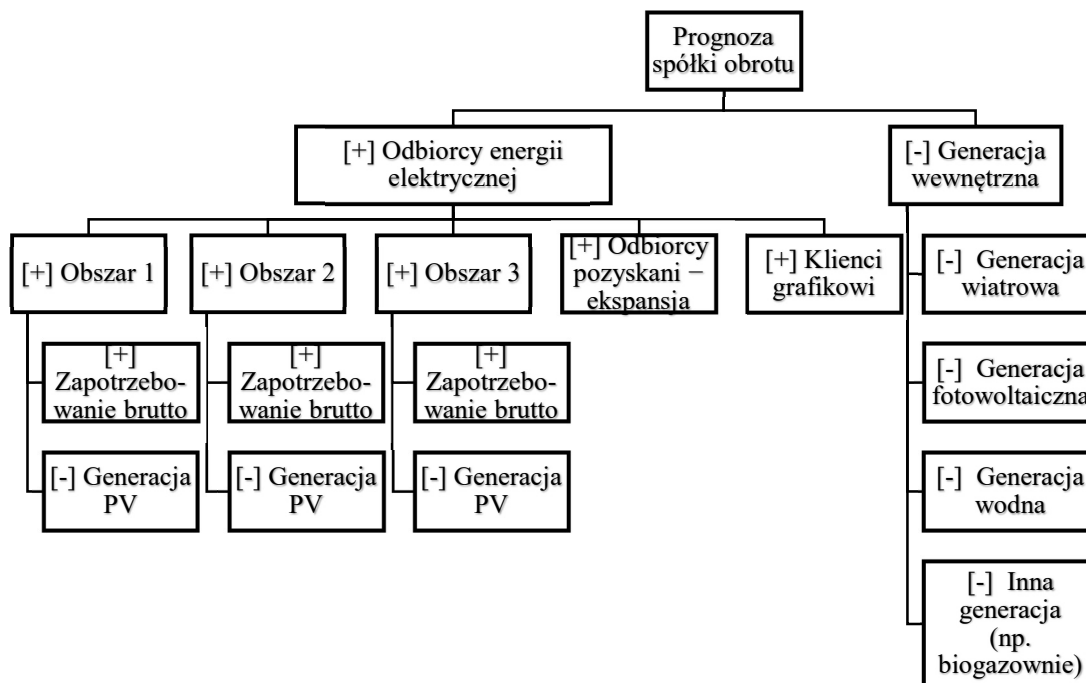


Rys. 3.13. Geograficzne rozmieszczenie mocy zainstalowanej u prosumentów w podziale na rejony dystrybucyjne
 Fig. 3.13. Geographical distribution of installed power of prosumers divided into distribution regions

Druga agregacja dotyczy odbiorców mających mikroinstalacje wytwarzające energię elektryczną. Instalacje fotowoltaiczne są agregowane pod względem mocy oraz położenia geograficznego, co przedstawiono na rysunku 3.13. Dane meteorologiczne z najbliższych stacji przyporządkowane są do obiektów zarówno zapotrzebowania brutto, jak i generacji fotowoltaicznej. Tworzone są nowe obiekty meteorologiczne odpowiadające obszarom, które zostały utworzone przez zagregowanie odbiorców z mikroinstalacjami PV. Nowe obiekty uśredniają dane meteorologiczne z okolicznych lokalizacji. W ten sposób obiekt o parametrach meteorologicznych natężenia promieniowania i temperatury powietrza odpowiada zapotrzebowaniu i generacji na

wyznaczonym obszarze. Geograficznie największa liczba odbiorców występuje w południowo-zachodniej części Polski.

Na poniższym schemacie (rys. 3.14) wyszczególnione zostały grupy odbiorców i wytwórców, wchodzących w skład zagregowanej pozycji handlowej spółki obrotu.



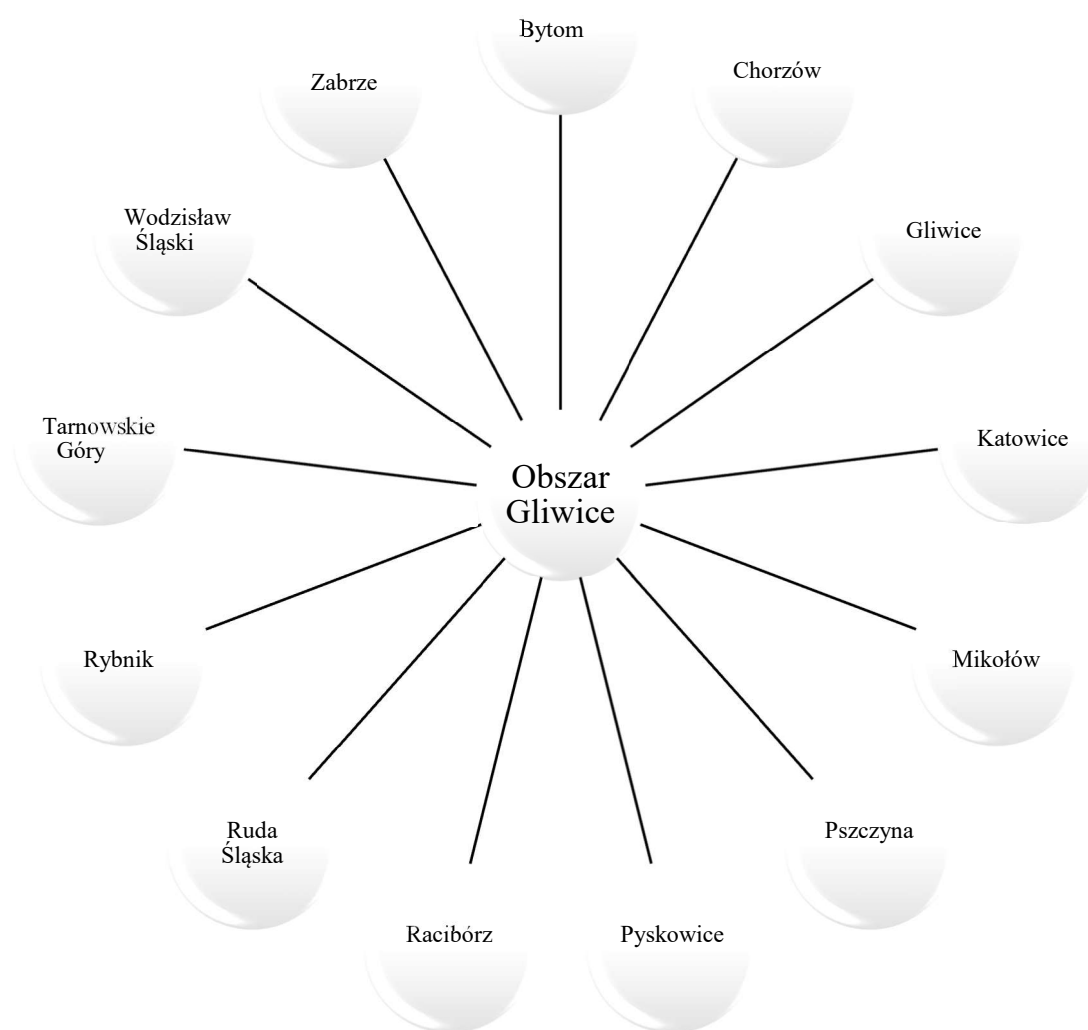
Rys. 3.14. Składowe prognozy wchodzące w sumę pozycji handlowej spółki obrotu

Fig. 3.14. Forecast components included in the total of the trading position of the trading company

Grupy odbiorców oznaczenie zostali znakiem + a grupy wytwórców ze znakiem -. Szczególnym przypadkiem są odbiorco-wytwórcy nazywani prosumentami. W ich przypadku występuje zarówno pobieranie jak i wytwarzanie energii elektrycznej, przy czym w przypadku generacji PV, mierzy się jedynie energię wprowadzoną do sieci dystrybucyjnej. Szczegółowe omówienie problematyki prosumentów będzie przedstawione w dalszej części pracy.

W zliberalizowanym rynku energii elektrycznej, jej sprzedaż nie ma ograniczeń terytorialnych w Polsce. Docelowo projektowane rozwiązania rynku energii przewidują zniesienie ograniczeń w handlu detalicznym na terenie Unii Europejskiej. W związku z powyższym, odbiorcy pozyskani w ramach ekspansji zostali zagregowani w specjalnie do tego utworzonym obiekcie o nazwie „odbiorcy pozyskani”. W przypadku tej grupy odbiorców prosumenci nie występują lub występują w pomijalnej liczbie (na chwilę obecną). W przypadku gdyby nastąpił wzrost udziału prosumentów w tej grupie odbiorców, to należałoby zastosować analogiczne podejście do obszarów brutto i generacji PV. Kolejną grupą odbiorców są klienci grafikowi. Grupa oznacza odbiorców, którzy dostarczają do spółki obrotu dobowe, tygodniowe bądź miesięczne prognozy zapotrzebowania. Taki grafik może służyć do rozliczenia klienta, może także być uwzględniony w ostatecznej prognozie lub skorygowany przez eksperta. Ostatnim elementem jest generacja lokalna. Są to instalacje wytwórcze, z którymi spółka obrotu

ma umowę na zakup wygenerowanej przez nie energii elektrycznej. Najczęściej są to niewielkie moce wytwórcze, podzielone ze względu na typ produkcji. W tej grupie wyróżnia się źródła wiatrowe, fotowoltaiczne, wodne oraz inne, np. biogazownie. Cała grupa oznaczona jest znakiem minus, co oznacza, że wolumen potrzebny do zakupu energii elektrycznej na giełdzie dla odbiorców spółki obrotu jest pomniejszany o wolumen zakupiony od wytwórców. Agregacji klientów można dokonać ze względu na lokalizację geograficzną, podobnie jak generację fotowoltaiczną, która zostanie przedstawiona w kolejnym podrozdziale. Na schemacie 3.15 przedstawiono podział obszaru Gliwice, dokonany bardziej szczegółowo na podobszary, reprezentujące rejony dystrybucyjne.



Rys. 3.15. Agregacja klientów w podziale na rejony dystrybucyjne

Fig. 3.15. Customer aggregation by distribution regions

W tabeli 3.2 przedstawiono udziały procentowe produkcji energii z mikroinstalacji fotowoltaicznych w okresie od stycznia do maja 2022 roku z obszaru Gliwice, w podziale na rejony. Z przedstawionych danych wynika, że największą produkcję energii elektrycznej odnotowano w rejonie: Rybnika, Wodzisławia Śląskiego

i Mikołowa; z kolei najmniejszą produkcję w rejonie Bytomia i Zabrze. Powyższe dane o udziale procentowym produkcji energii elektrycznej odpowiadają danym o mocy zainstalowanej w mikroinstalacjach PV, która również została przedstawiona w tabeli 3.2.

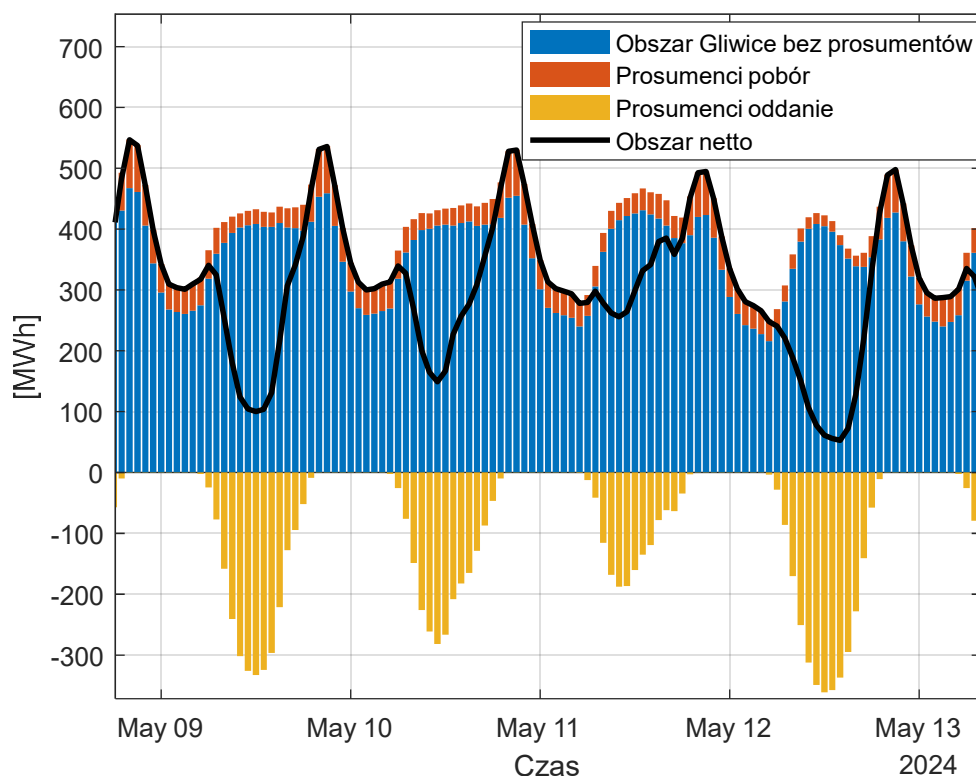
Tab. 3.2. Udział mocy zainstalowanej w mikroinstalacjach fotowoltaicznych oraz w generacji na obszarze Gliwice, w podziale na rejony

Table 3.2. Share of installed power in photovoltaic micro-installations and in generation in the Gliwice area, divided into regions

Rejon	Udział procentowy w mocy zainstalowanej	Udział procentowy w generacji PV (styczeń-maj 2022)
Bytom	2%	2%
Chorzów	3%	2%
Gliwice	10%	8%
Katowice	4%	3%
Mikołów	16%	17%
Pszczyna	7%	7%
Pyskowice	7%	5%
Racibórz	6%	6%
Ruda Śląska	3%	3%
Rybnik	17%	19%
Tarnowskie Góry	6%	6%
Wodzisław Śląski	16%	18%
Zabrze	2%	2%

Na wykresie 3.16 przedstawiono zapotrzebowanie na energię elektryczną (w megawatogodzinach, MWh) zagregowane (obszar netto) oraz zdezagregowane (pozostałe 3 składowe) w ujęciu czasowym:

- Bez prosumentów (kolor niebieski) – zapotrzebowanie na energię bez udziału prosumentów, czyli użytkownicy, którzy tylko pobierają energię elektryczną z sieci dystrybucyjnej.
- Prosument pobór (kolor pomarańczowy) – energia pobierana przez prosumentów, użytkownicy, którzy mają własne instalacje fotowoltaiczne mogą jednocześnie pobierać energię z sieci dystrybucyjnej i oddawać energię elektryczną do sieci dystrybucyjnej.
- Prosument oddanie (kolor żółty) – energia oddawana do sieci przez prosumentów.
- Suma (czarna linia) – suma trzech powyższych składników dająca profil zapotrzebowania netto.



Rys. 3.16. Zapotrzebowanie na energię elektryczną, przedstawione jako szereg czasowy, w podziale na składowe zapotrzebowania bez prosumentów, zapotrzebowanie prosumentów, oddanie energii do sieci przez prosumentów
 Fig. 3.16. Electricity demand presented as a time series, divided into demand components without prosumers, prosumer demand, energy fed into the grid by prosumers

3.8 Agregacja zmiennych objaśniających

Idealnym rozwiązaniem w prognozowaniu generacji fotowoltaicznej jest punktowy pomiar pojedynczej instalacji oraz zmienne objaśniające (temperatura i natężenie promieniowania słonecznego) dla tej lokalizacji. Jednak z uwagi na koszty i czasochłonność, rozwiązanie to nie jest używane w praktyce. W większości przypadków stosuje się agregację źródeł PV. W niniejszych rozważaniach przyjęto agregację stosowaną przez operatora systemu dystrybucyjnego. Agregacja ta jest sprowadzona do rejonów dystrybucyjnych, które, w większości przypadków, odpowiadają obszarowi powiatu. Dane pogodowe są pobierane dla centrów geometrycznych, w których występuje największe skupisko instalacji fotowoltaicznych. W praktyce są to miasta powiatowe. Liczba lokalizacji, dla których należy pobrać dane na chwilę obecną wynosi 68. W tabeli 3.3 zostały przedstawione współrzędne geograficzne dla lokalizacji, dla których są pobierane prognozy temperatury i natężenia promieniowania słonecznego.

Tab. 3.3. Geograficzne rozmieszczenie mikroinstalacji przyłączonych do poszczególnych rejonów dystrybucyjnych wraz z mocą zainstalowaną instalacji PV

Tab. 3.3. Geographical distribution of micro-installations connected to individual distribution regions along with the installed capacity of PV installations

Rejon dystrybucyjny (RD)	Obszar	Szerokość °N	Długość °E	Moc zainstalowana w kWp*
RD 1	1	49.819	19.049	86 872
RD 2	1	49.750	18.629	81 983
RD 3	1	49.879	19.489	79 694
RD 4	1	49.689	19.205	73 202
RD 5	1	49.883	19.221	45 318
RD 6	1	50.279	19.120	14 270
RD 7	1	50.340	19.129	36 624
RD 8	1	50.330	19.180	16 804
RD 9	1	50.209	19.270	20 490
RD 10	1	50.160	19.450	28 959
RD 11	1	50.489	19.420	37 522
RD 12	1	50.240	19.140	20 812
RD 13	1	50.279	19.549	26 613
RD 14	1	50.810	19.129	91 486
RD 15	1	50.580	19.319	47 033
RD 16	1	50.669	18.689	57 714
RD 17	1	50.909	18.940	59 131
RD 18	1	50.060	19.959	348 808
RD 19	1	49.289	19.959	21 266
RD 20	1	49.489	20.030	81 781
RD 21	1	49.709	20.419	45 674
RD 22	1	49.630	20.699	97 457
RD 23	1	50.009	20.990	78 270
RD 24	1	50.060	21.420	54 294
RD 25	1	49.979	20.429	49 082

Prognozowanie zapotrzebowania na energię elektryczną i gaz w firmie TAURON

Sprzedaż sp. z o.o. w horyzoncie krótkoterminowym

RD 26	1	50.179	21.000	35 035
RD 1	2	50.909	15.729	41 199
RD 2	2	51.259	15.560	28 284
RD 3	2	51.119	15.280	29 028
RD 4	2	51.209	16.159	32 544
RD 5	2	51.669	16.080	24 067
RD 6	2	51.280	15.930	16 922
RD 7	2	51.399	16.200	29 922
RD 8	2	50.679	17.940	64 476
RD 9	2	51.079	17.719	16 625
RD 10	2	50.980	18.209	15 579
RD 11	2	50.520	18.299	44 665
RD 12	2	50.340	18.209	53 140
RD 13	2	50.479	17.339	42 956
RD 14	2	50.466	17.011	13 836
RD 15	2	50.849	17.470	20 588
RD 16	2	50.780	16.280	16 401
RD 17	2	50.959	16.350	30 868
RD 18	2	50.729	16.650	35 286
RD 19	2	50.439	16.659	34 476
RD 20	2	51.110	17.030	69 049
RD 21	2	51.298	16.901	45 621
RD 22	2	51.209	17.379	77 011
RD 23	2	50.780	17.069	34 643
RD 24	2	51.163	16.595	53 685
RD 1	3	50.310	18.669	55 510
RD 2	3	50.299	18.779	13 473
RD 3	3	50.349	18.909	11 902
RD 4	3	50.410	18.620	38 344

RD 5	3	50.299	19.030	13 932
RD 6	3	50.163	18.903	86 798
RD 7	3	50.259	19.020	20 034
RD 8	3	50.459	18.860	33 996
RD 9	3	50.299	18.880	16 609
RD 10	3	50.090	18.219	33 220
RD 11	3	50.100	18.549	91 843
RD 12	3	50.002	18.463	86 166
RD 13	3	49.979	18.950	38 522

*Moc zainstalowana – stan na czerwiec 2024 roku

Żeby możliwe było zastosowanie prognoz meteorologicznych do modelowania generacji PV na obszarze, konieczna jest agregacja prognoz, która przebiega zgodnie ze wzorem (3.2):

$$M_{zagr} = \sum_{i=1}^k M_i w_i \quad (3.2)$$

gdzie:

M_{zagr} – zagregowana prognoza na obszarze w danym okresie,

M_i – prognoza i-tego regionu,

w_i – waga i-tego regionu, wyznaczona według wzoru (3.3):

$$w_i = \frac{P_{zainst_i}}{P_{zainst}} \quad (3.3)$$

gdzie:

P_{zainst_i} – moc zainstalowana w i-tym regionie,

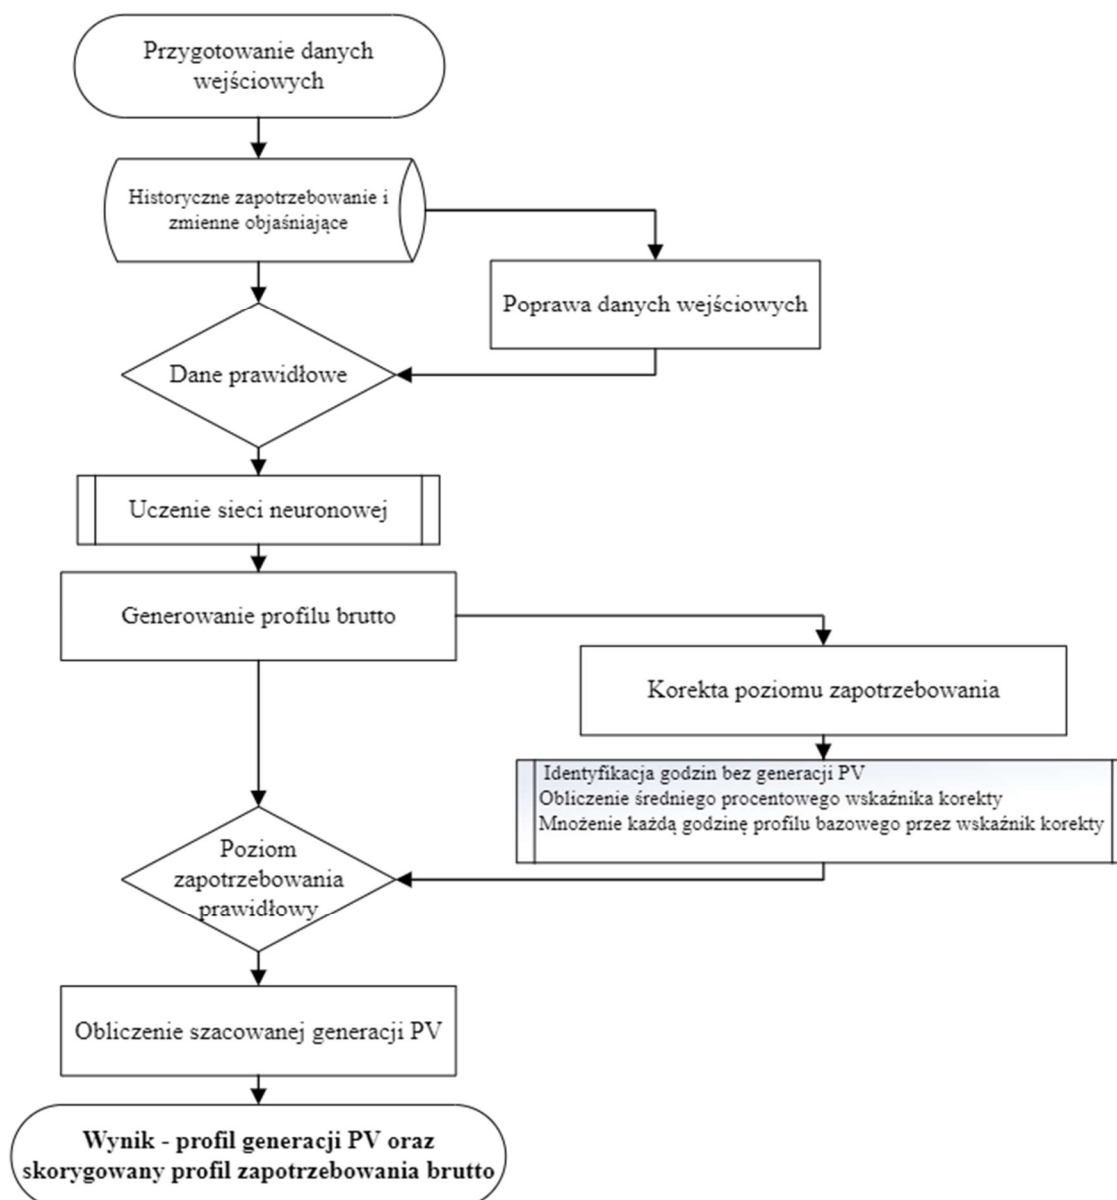
P_{zainst} – moc zainstalowana w całym obszarze, w skład którego wchodzi rejony.

Agregowanie prognoz meteorologicznych, z uwzględnieniem mocy zainstalowanej w regionie, daje wiele pozytywnych efektów, które mogą poprawić dokładność i stabilność prognoz. Najważniejsze z nich to redukcja błędów losowych prognoz oraz lepsza odporność na szum.

4 METODYKA GENERACJI PROFILU ZAPOTRZEBOWANIA BRUTTO

4.1 Historyczny profil zapotrzebowania brutto

Podjęto próbę opracowania nowej metody, nazwanej metodą generacji brutto. Kluczowym elementem tej metody jest oddzielenie składowej zapotrzebowania związanej z generacją PV i odtworzenia profilu zapotrzebowania bez udziału mikroinstalacji fotowoltaicznych. Schematycznie pokazano to na rysunku 4.1.

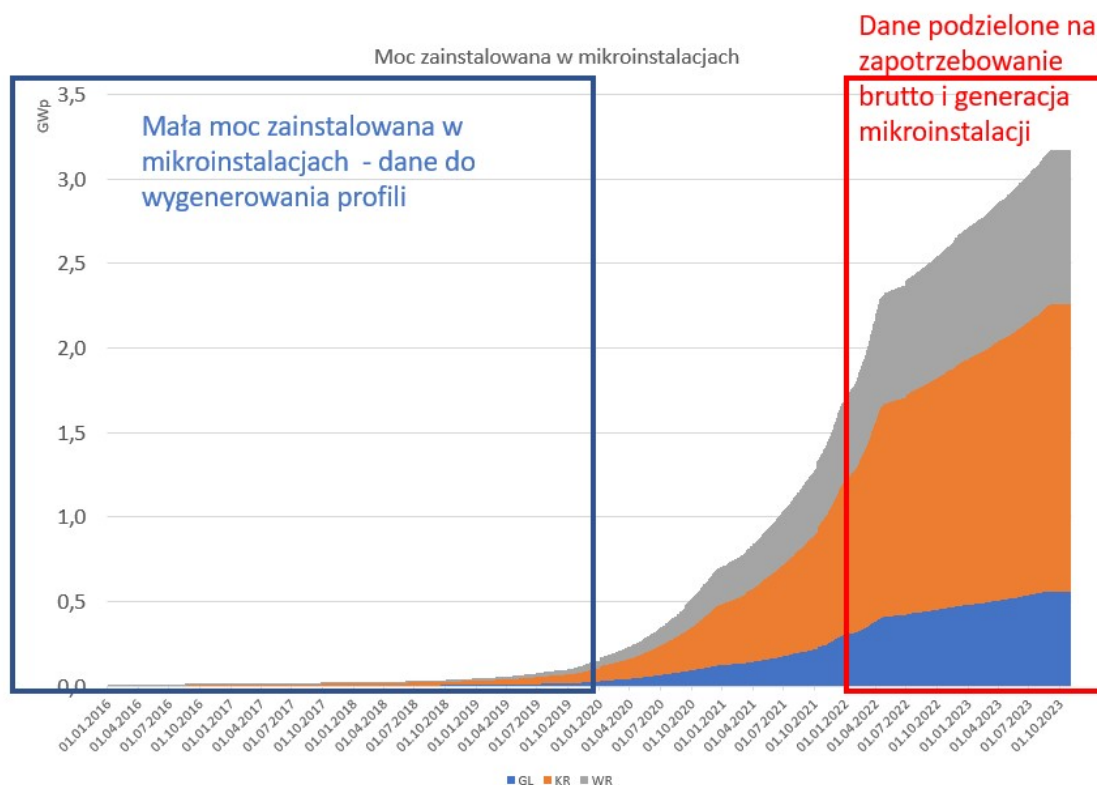


Rys. 4.1. Algorytm do odtworzenia profilu brutto i generacji PV

Fig. 4.1. Algorithm to recreate gross profile and PV generation

Do tak sformułowanego zadania wybrano sieć neuronową, która powinna precyzyjnie odwzorować profil zapotrzebowania na energię elektryczną, przy niewielkim udziale mikroinstalacji PV. Proces uczenia sieci przeprowadzono na danych z okresu

2016-2019. W celu utrzymania aktualności modelu możliwe jest dalsze trenowanie sieci neuronowej na danych dotyczących zapotrzebowania brutto. Należy jednak zapewnić odpowiednią jakość i poprawność danych wykorzystywanych w procesie uczenia. Przyrost mocy zainstalowanej mikroinstalacjach w spółce obrotu przedstawia poniższy wykres 4.2.



Rys. 4.2. Dane o mocy zainstalowanej mikroinstalacji PV w latach 2016-2024, w podziale na dane uczące i dane do odtworzenia profilu brutto
 Fig. 4.2. Data on the installed capacity of PV micro-installations in 2016-2024 divided into training data and data for gross profile reconstruction

Dane są agregowane do trzech obszarów, zgodnie z obecną polityką agregacji stosowaną w spółce obrotu, ale nie ma przeciwskazań do innego sposobu agregacji danych. Obszar 2 obejmuje województwa dolnośląskie i opolskie. Obszar 3 obejmuje Górny Śląsk, a obszar 1 – województwo małopolskie i część województwa śląskiego. Różnica pomiędzy profilem zapotrzebowania brutto, wyznaczonym na podstawie modelu sieci neuronowej a zapotrzebowaniem netto (dane rzeczywiste) to szacowana generacja z mikroinstalacji PV. Założenie to zostało opisane poniższym wzorem (4.1):

$$E_{PV} = E_B - E_N \quad (4.1)$$

gdzie:

E_{PV} – szacowana generacja z mikroinstalacji PV na obszarze,

E_B – profil zapotrzebowania obszaru brutto,

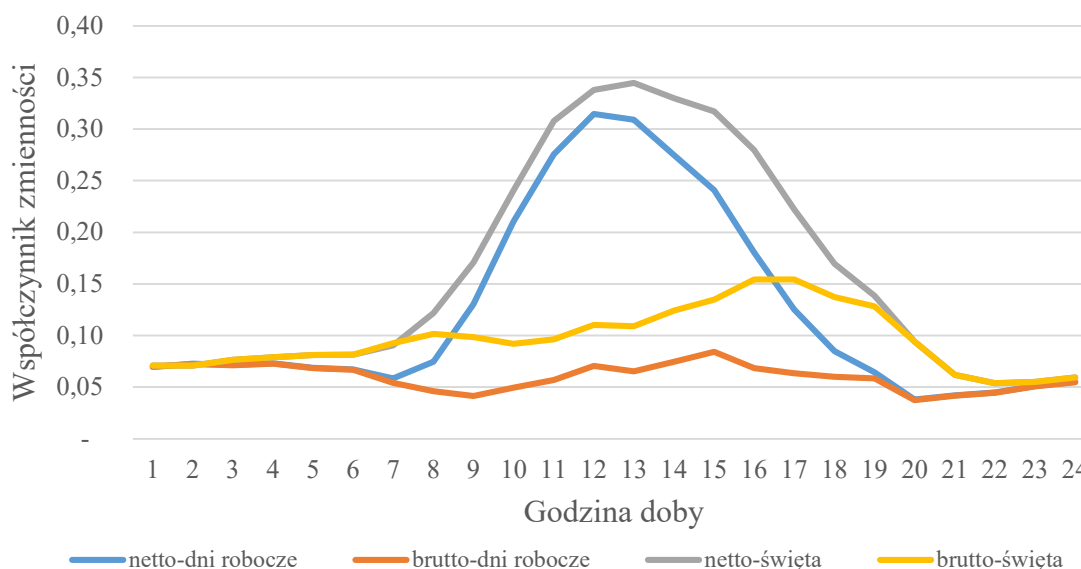
E_N – profil zapotrzebowania netto (dane rzeczywiste o zapotrzebowaniu odbiorców obszaru na energię elektryczną).

4.2 Współczynnik zmienności

Zmiany na rynku energii elektrycznej umożliwiły rozwój mikroinstalacji fotowoltaicznych oraz wprowadzenie nowego uczestnika rynku, jakim jest prosument. Spowodowały również zmiany w charakterze poboru energii elektrycznej. Duże nasycenie mikroinstalacjami fotowoltaicznymi powoduje zmiany profilu zapotrzebowania w skali całej spółki obrotu. Klasyczna miara zróżnicowania rozkładu jakiejś cechy to współczynnik zmienności. W odróżnieniu od odchylenia przeciętnego, które określa bezwzględne zróżnicowanie cechy, współczynnik zmienności jest miarą względną, czyli zależną od wielkości średniej arytmetycznej. Może mieć zastosowanie w przypadku energii elektrycznej, co wynika z pojawienia się generacji PV, powodującej zmienność w określonych godzinach doby [136]. Współczynnik zmienności nie będzie miał zastosowania w przypadku gazu ziemnego, ponieważ jego pobór przez odbiorców w trakcie dnia jest w miarę stały i w dużym stopniu zależny od temperatury powietrza. W przypadku zapotrzebowania na energię elektryczną można go zdefiniować wzorem (4.2):

$$Cv = \frac{\text{Odchylenie standardowe}}{\text{Średnie zapotrzebowanie}} \quad (4.2)$$

Godzinowy rozkład wskaźnika zmienności zapotrzebowania wskazuje generację fotowoltaiczną jako główny czynnik zwiększonej zmienności, co pokazano na poniższym wykresie (rys. 4.3).



Rys. 4.3. Porównanie średniego współczynnika zmienności dla zapotrzebowania netto i brutto w godzinach doby

Fig. 4.3. Comparison average coefficient of variation for net and gross demand during the day

Zwiększona zmienność zapotrzebowania w określonych godzinach jest związana z generacją fotowoltaiczną mikroinstalacji prosumenckich [89, 90, 91]. Generacja

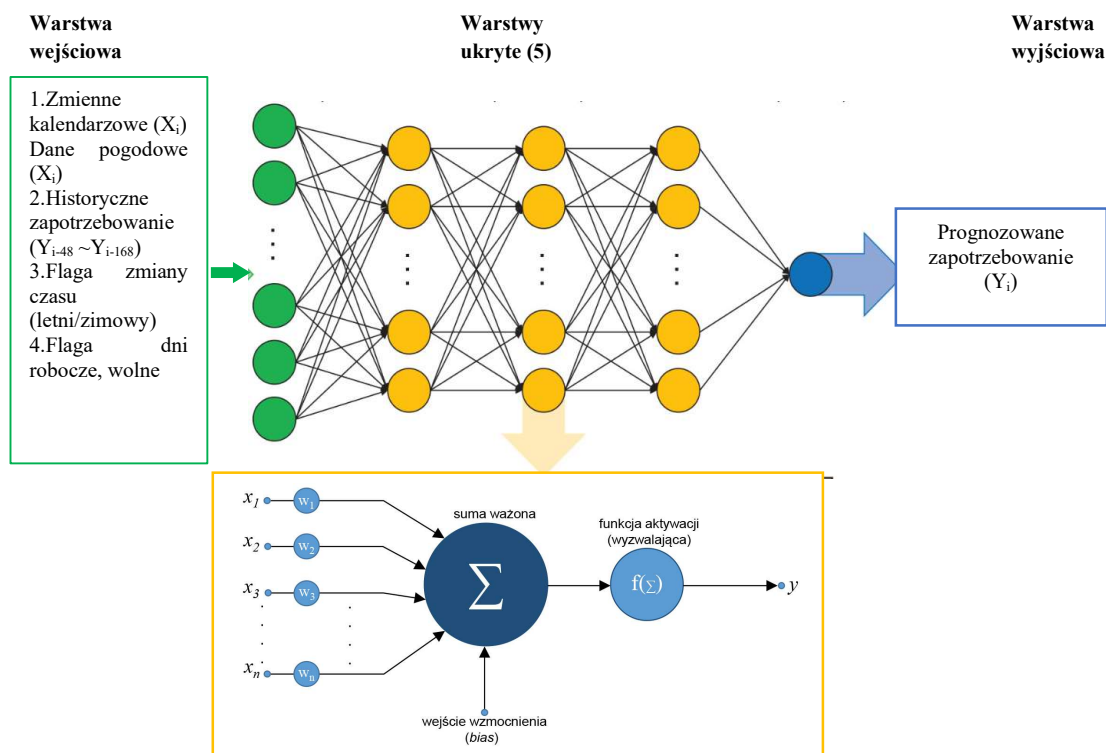
z mikroinstalacji fotowoltaicznych jest ściśle skorelowana z natężeniem promieniowania słonecznego. W większości przypadków mikroinstalacje nie są wyposażone w system magazynowania energii, co powoduje wprowadzanie nadmiaru energii elektrycznej do sieci dystrybucyjnej. W efekcie prowadzi to do spadku zapotrzebowania na energię elektryczną w spółce obrotu [92]. Jest to jedną z przyczyn rozbieżności pomiędzy prognozą a rzeczywistym zapotrzebowaniem na energię elektryczną [93]. Różne propozycje rozwiązania tego problemu można znaleźć w wielu pozycjach literaturowych [94, 95, 96].

4.3 Model sieci neuronowej

Model sieci neuronowej wykorzystany do generacji profilu brutto jest trenowany na historycznych danych. Zmiennymi objaśniającymi w modelu są zmienne:

- kalendarzowe (funkcje określające ułamki: doby, miesiąca, roku),
- pogodowe (temperatura średnia w godzinie, temperatura maksymalna w dobie, temperatura minimalna w dobie),
- historyczne zapotrzebowanie z poprzednich okresów (w tym wartości średnie, minimalne i maksymalne oraz odniesione do temperatury, tj. MWh/°C).

Sieć neuronowa składa się z 5 ukrytych warstw, z każdą warstwą zawierającą 10 neuronów, co przedstawiono na rysunku 4.4



Rys. 4.4. Schemat struktury sieci neuronowej do generacji profilu zapotrzebowania brutto

Fig. 4.4. Schematic diagram of the neural network structure for generating the gross demand profile

Pięciowarstwowa struktura sieci jest formą głębokiej sieci neuronowej (deep neural network), co pozwala modelowi na uchwycenie bardziej złożonych i nieliniowych zależności w danych. Układ neuronów (głębokość sieci) sprawia, że model ma dużą zdolność reprezentacyjną, co oznacza, że może nauczyć się bardziej skomplikowanych wzorców z danych. Należy jednak uważać na nadmierne skomplikowanie modelu, ponieważ może to prowadzić do przeuczenia. Założono, że 95% danych zostanie użytych do trenowania modelu, a pozostałe niewielkie porcje danych zostaną użyte do walidacji i testowania. Model sieci neuronowej do generacji zapotrzebowania brutto, uwzględniając historyczne zapotrzebowanie, generuje przewidywany profil, który nie zawiera generacji fotowoltaicznej z instalacji PV prosumentów. Jest to odtworzony profil zapotrzebowania brutto. W związku z migracją klientów, a także okresowymi trendami wzrostu i spadku zapotrzebowania, konieczne jest wykonanie korekty poziomu zapotrzebowania brutto. Dokonywane jest to przy uwzględnieniu tylko tych godzin, w których generacja fotowoltaiczna się nie pojawia. W tym celu sprawdzany jest warunek, w którym nasłonecznienie w godzinie jest równe zero, tj. $S_t=0$. Dla takiego zestawu danych obliczany jest średni dobowy, procentowy wskaźnik różnicy poziomu zapotrzebowania, zgodnie ze wzorem (4.2):

$$W_{avg} = \frac{1}{N} \sum_{t=1}^N \frac{ER_t - Z_{brutto,t'}}{ER_t} 100\% \text{ dla } S_t=0 \quad (4.2)$$

gdzie:

W_{avg} – procentowa korekta poziomu,

S_t – natężenie promieniowania słonecznego,

ER_t – energia rzeczywista (zapotrzebowanie netto) w godzinie t ,

$z_{brutto,t}'$ – profil zapotrzebowania brutto przed korektą w godzinie t .

Profil brutto w całości, tj. każda godzina jest mnożona wskaźnikiem W_{avg} , zgodnie ze wzorem 4.3:

$$z_{brutto,t}'' = z_{brutto,t}' * (1 + W_{avg}) \quad (4.3)$$

gdzie

z_{brutto}'' – profil zapotrzebowania brutto po korekcie, w godzinie t .

W kolejnym kroku następuje obliczenie szacowanej generacji PV z mikroinstalacji fotowoltaicznych. W praktyce jest to różnica pomiędzy profilem brutto a profilem netto, zgodnie ze wzorem 4.4:

$$G_{PV,t} = z_{brutto,t}'' - ER_t \quad (4.4)$$

gdzie

$G_{PV,t}$ – szacowana generacja PV z mikroinstalacji w godzinie t .

Szacowany profil generacji mikroinstalacji PV poddawany jest kontroli w dwóch warunkach, zgodnie ze wzorem 4.5. Korygowane są wartości odstające, np. mniejsze od 0 lub mniejsze od wartości oddania energii elektrycznej do sieci. W obu przypadkach algorytm przyjmuje wartości oddania energii elektrycznej do sieci przez prosumentów, powiększony o średni współczynnik autokonsumpcji, założony na poziomie 20%.

$$\text{Jeżeli } G_{PV,t} < 0 \text{ lub } G_{PV,t} < P_{odd}, \text{ wtedy } G_{PV,t} = P_{odd} * (1 + \alpha) \quad (4.5)$$

gdzie:


P_{odd} – energia oddana do sieci w godzinie t ,

α – współczynnik autokonsumpcji (20%).

4.4 Wyniki uczenia sieci neuronowej

Dane zostały przekazane do treningu sieci neuronowej. Na początku procesu uczenia błąd (MSE – Mean Squared Error) dla danych treningowych (niebieska linia) szybko spada, co przedstawiają wykresy poniżej (rys. 4.5, 4.6, 4.7). Sieć neuronowa zaczyna dopasowywać się do wzorców w danych, ucząc się najpierw dużych, łatwych do wykrycia zależności. Zauważalny, szybki spadek błędu na początku jest normalny i wskazuje na prawidłowe działanie procesu uczenia. Linie dla danych walidacyjnych (zielona) oraz testowych (czerwona) są blisko siebie i zbieżne z krzywą dla danych treningowych. Oznacza to, że model nie jest przetrenowany (overfitting), a proces uczenia dobrze przebiega również na nowych, niewidzianych wcześniej danych. To


sugeruje, że model jest dobrze dopasowany zarówno do danych treningowych, jak i walidacyjnych/testowych.



Rys. 4.5. Proces uczenia sieci neuronowej – obszar 1

Fig. 4.5. Neural network training process – area 1


Wykresy wskazują, że po około 59 epokach dla pierwszego obszaru i 70 epokach dla pozostałych błęd osiąga najniższą wartość (najlepszy punkt oznaczony zielonym okręgiem). Po tej liczbie epok dalsze uczenie prawdopodobnie nie przyniosłoby znaczącej poprawy, a może nawet spowodowałoby pogorszenie wyników wskutek nadmiernego dopasowania. Punkt ten wskazuje na optymalną liczbę epok, gdzie model osiąga najlepsze wyniki.



Rys. 4.6. Proces uczenia sieci neuronowej – obszar 2

Fig. 4.6. Neural network training process – area 2


Zielona, pozioma linia oznacza minimalny osiągnięty błąd. Jest to punkt, w którym model uzyskał najlepszą dokładność, co wskazuje na sukces w treningu modelu.



Rys. 4.7. Proces uczenia sieci neuronowej – obszar 3

Fig. 4.7. Neural network training process – area 3


Na wykresach 4.8, 4.9 i 4.10 przedstawiono wskaźniki związane z procesem uczenia sieci neuronowej. Na górnym wykresie pokazany jest spadek gradientu podczas treningu sieci. Gradient odnosi się do wartości pochodnej funkcji błędu względem wag w sieci neuronowej. Spadek gradientu sugeruje, że sieć uczy się, a błąd maleje w miarę dopasowywania wag. Na początku gradient ma wysoką wartość, ale z biegiem epok stopniowo maleje, co oznacza, że sieć zbliża się do minimum funkcji kosztu (proces konwergencji). Zbyt niski gradient może oznaczać problem tzw. zanikającego gradientu, co może zatrzymać proces uczenia. Na wykresach gradient po około 30 epokach stabilizuje się, co może wskazywać na zakończenie uczenia.



Rys. 4.8. Wskaźniki związane z procesem uczenia sieci neuronowej – obszar 1

Fig. 4.8. Indicators related to the neural network training process – area 1

Wartość μ odnosi się do współczynnika Levenberga-Marquardta, który reguluje równowagę między optymalizacją metodą Gaussa-Newtona a metodą gradientu prostego. Wykres μ na początku wzrasta, a potem stabilizuje się na stałym poziomie, co oznacza, że algorytm dostosowuje swoje działanie w odpowiedzi na zmianę gradientu i nie jest już potrzebne duże dostosowywanie. Stała wartość μ sugeruje, że sieć działa w stabilnym trybie optymalizacji.




Rys. 4.9. Wskaźniki związane z procesem uczenia sieci neuronowej –obszar 2

Fig. 4.9. Indicators related to the neural network training process – area 2

Dolny wykres przedstawia liczbę epok, w których sieć neuronowa nie poprawiła wyniku walidacji. W miarę postępu treningu, punkty walidacyjne oznaczone diamentami zaczynają rosnąć, co dowodzi, że model zaczyna tracić na dokładności względem danych


walidacyjnych. W przypadku gwałtownego wzrostu braku poprawy walidacji (jak po około 50 epokach dla obszaru 1 lub 70 epokach dla obszaru 3) może to oznaczać, że model zaczyna się przeuczać (overfitting), ponieważ poprawia się dla danych treningowych, ale jego skuteczność na danych walidacyjnych maleje.



Rys. 4.10. Wskaźniki związane z procesem uczenia sieci neuronowej – obszar 3


Fig. 4.10. Indicators related to the neural network training process – area 3

Na załączonych poniżej wykresach (rys. 4.11, 4.12 i 4.13) przedstawiona jest dystrybucja błędów dla trzech zestawów danych: treningowego (niebieski), walidacyjnego (zielony) oraz testowego (czerwony). Większość odchyłeń znajduje się blisko błędu zerowego, co oznacza, że dla większości danych model dobrze przewiduje prognozowaną zmienną. Są także przypadki z większym błędem, co wskazuje na trudniejsze przykłady dla modelu. Jednak dane walidacyjne, testowe i treningowe mają podobny rozkład błędów, co wskazuje, że model dobrze generalizuje na nowych danych i nie wykazuje oznak overfittingu.




Rys. 4.11. Rozkład błędów historycznego profilu brutto – obszar 1

Fig. 4.11. Distribution of historical gross profile errors – area 1



Rys. 4.12. Rozkład błędów historycznego profilu brutto – obszar 2

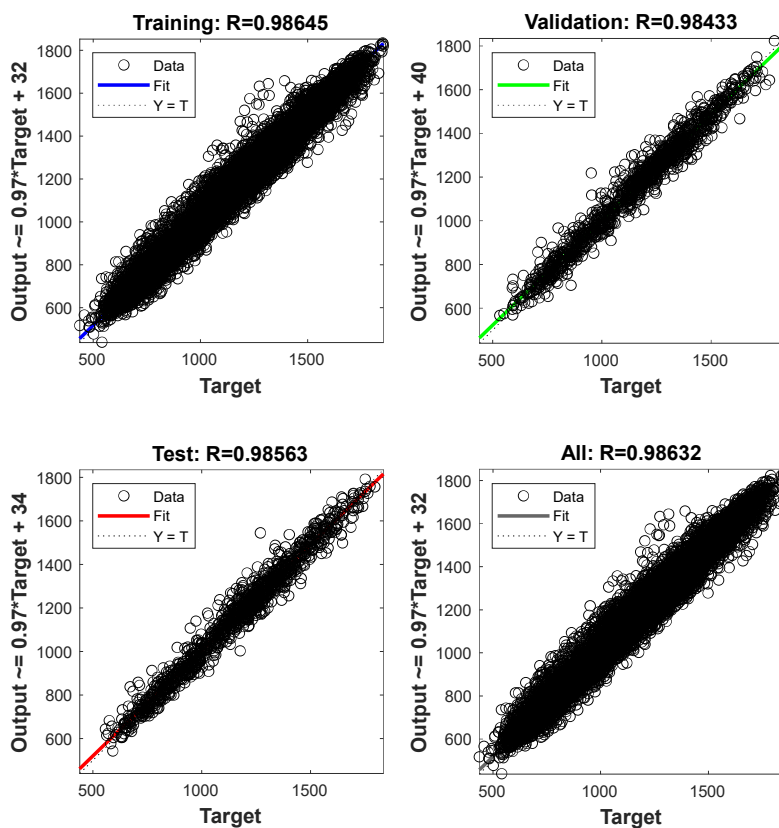
Fig. 4.12. Distribution of historical gross profile errors – area 2



Rys. 4.13. Rozkład błędów historycznego profilu brutto – obszar 3

Fig. 4.13. Distribution of historical gross profile errors – area 3

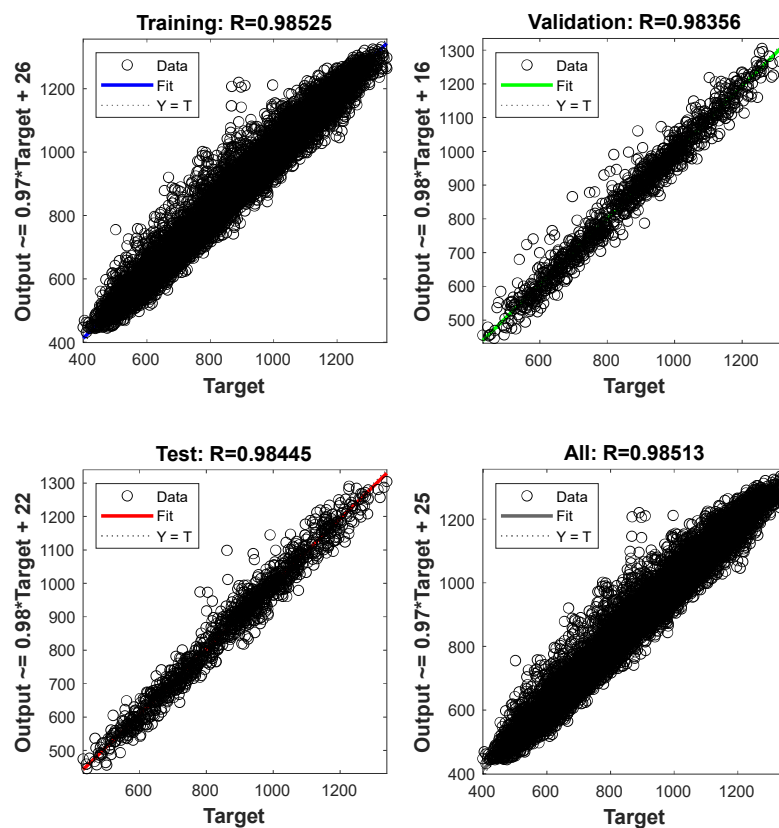
Na wykresach (rys. 4.14, 4.15 i 4.16) przedstawiono wartość dopasowania sieci neuronowej do danych uczących. Wartości współczynnika korelacji (R) są bardzo bliskie 1, co oznacza, że model ma wysoką dokładność w dopasowywaniu prognoz do danych rzeczywistych. Wartości te sugerują silną, liniową zależność między wartościami prognozowanymi a rzeczywistymi celami, co świadczy o dobrej jakości modelu.



Rys. 4.14. Wykres dopasowania modelu do danych – obszar 1

Fig. 4.14. Model fit to data graph – area 1

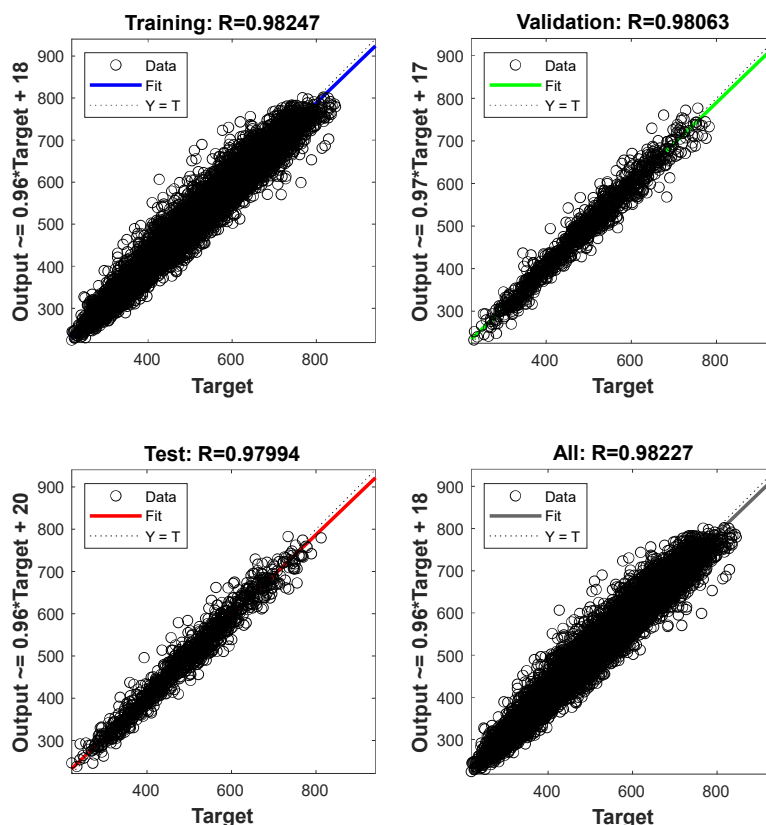
Na każdym z wykresów przedstawiono linię regresji dla danych prognozowanych względem rzeczywistych celów. Linie są bardzo blisko idealnej linii $Y=T$ (prognoza równa celowi), co wskazuje na to, że model dobrze przewiduje wartości dla wszystkich zbiorów danych (trening, walidacja, test). Różnice pomiędzy zbiorami treningowymi, walidacyjnymi i testowymi są minimalne, co oznacza, że model nie ma problemu z przeuczeniem, czyli nie jest nadmiernie dopasowany do danych treningowych i radzi sobie dobrze z danymi, których nie widział w trakcie uczenia.



Rys. 4.15. Wykres dopasowania modelu do danych – obszar 2

Fig. 4.15. Model fit to data graph – area 2

Każdy wykres zawiera informację o dopasowaniu w postaci wzoru, np. $Output \approx 0.97 * Target + 32$. Wartości te są bardzo bliskie idealnej relacji $Output = Target$, co oznacza, że błąd prognozy jest stosunkowo mały.




Rys. 4.16. Wykres dopasowania modelu do danych – obszar 3

Fig. 4.16. Model fit to data graph – area 3

4.5 Wyniki algorytmu


Wyniki działania algorytmu z wybranego okresu przedstawiono na wykresie 4.17. Pierwszy od góry wykres pokazuje korektę danych, która jest kalkulowana jako średnia procentowa różnica danych modelowych w stosunku do danych rzeczywistych, w godzinach, w których generacja PV jest równa 0. Pozwala to na dostosowanie poziomu zapotrzebowania profilu brutto do zmieniających się trendów w zapotrzebowaniu na energię elektryczną. Na kolejnych, tj. trzecim i czwartym wykresach przedstawiono zapotrzebowanie netto, które uwzględnia generację mikroinstalacji PV prosumentów oraz zapotrzebowanie brutto, które odzwierciedla takie zapotrzebowanie, jakie by było, gdyby nie generacji PV. Na ostatnim wykresie przedstawiona została oszacowana generacji mikroinstalacji PV prosumentów, stanowiąca różnicę pomiędzy profilami brutto a netto.



Rys. 4.17. Wyniki algorytmu szacowania profilu brutto i generacji fotowoltaicznej


Fig. 4.17. Results of the gross profile estimation algorithm and photovoltaic generation

Wykresy poniżej (rys. 4.18, 4.19 i 4.20) przedstawiają profil netto (ER) oraz profil brutto przed korektą (SSN przed korektą) i profil brutto po korekcie (SSN po korekcie). Wszystkie wykresy pokazują takie same trendy dobowe i zależność od generacji fotowoltaicznej. Wzrastająca generacja PV powoduje zmniejszenie zapotrzebowania na energię elektryczną. W przypadku obszaru 1, minimalne zapotrzebowanie netto w dniu 1 maja 2024 roku wyniosło -26 MW. Na obszarach 2 i 3 minimum wystąpiło w dniu 12 maja 2024 o godzinie 15 i wyniosło odpowiednio 109 MW i 53 MW. W kolejnych latach, wraz ze wzrostem mocy zainstalowanej w PV oraz domowych magazynach energii, należy spodziewać się jeszcze niższego zapotrzebowania na energię elektryczną w godzinach „słonecznych” oraz dalszego ogólnego spadku zapotrzebowania w spółce obrotu.




Rys. 4.18. Obszar 1 – profil netto oraz profil brutto po korekcie

Fig. 4.18. Area 1 – net profile and gross profile after correction



Rys. 4.19. Obszar 2 – profil netto oraz profil brutto po korekcie


Fig. 4.19. Area 2 – net profile and gross profile after correction



Rys. 4.20. Obszar 3 – profil netto oraz profil brutto po korekcie


Fig. 4.20. Area 3 – net profile and gross profile after correction

Na wykresach 4.21, 4.22 i 4.23 przedstawiono dwie kluczowe linie, które odnoszą się do generacji PV oraz energii oddanej do sieci, a także linię przedstawiającą moc zainstalowaną w instalacjach prosumenckich na badanych obszarach.




Rys. 4.21. Obszar 1 – generacja PV i oddanie energii do sieci

Fig. 4.21. Area 1 – PV generation and energy feed-in to the grid



Rys. 4.22. Obszar 2 – generacja PV i oddanie energii do sieci

Fig. 4.22. Area 2 – PV generation and energy feed into the grid




Rys. 4.23. Obszar 3 – generacja PV i oddanie energii do sieci

Fig. 4.23. Area 3 – PV generation and energy feed into the grid


Przedstawiona zmienność generacji PV wynika z cykli dziennych (wskazane na wykresie przez szczyty i doliny produkcji). Tego typu zmienność stanowi wyzwanie dla spółek obrotu, ponieważ nadmierna generacja w południe może powodować spadek nawet do wartości ujemnych, natomiast w godzinach porannych i wieczornych, kiedy produkcja PV spada do zera, system musi kompensować to zwiększonym zapotrzebowaniem na energię z innych źródeł, co przekłada się na wysokie ceny energii. W przypadku rozwoju technologii magazynowania energii (baterii), energia ta mogłaby być gromadzona w godzinach szczytowej produkcji i wykorzystywana w okresach niedoboru, co znacznie zmniejszyłoby obciążenie sieci. W przypadku systemów prosumenckich, część energii generowanej przez instalacje PV jest konsumowana bezpośrednio przez gospodarstwo domowe lub firmę (autokonsumpcja), a nadwyżka energii jest wprowadzana do sieci.

Różnica między całkowitą wygenerowaną energią a energią oddaną do sieci odzwierciedla autokonsumpcję. Na przedstawionych wykresach poniżej (rys. 4.24, 4.25 i 4.26) widać, że linia oznaczająca energię oddaną do sieci znajduje się poniżej linii generacji PV, co oznacza, że część wygenerowanej energii jest zużywana bezpośrednio na miejscu. Kształty obu krzywych są zbliżone, co oznacza, że energia oddana do sieci jest proporcjonalna do generacji PV, z tą różnicą, że autokonsumpcja zmniejsza ilość energii, która trafia do sieci.




Rys. 4.24. Obszar 1 – generacja PV i energia oddana do sieci

Fig. 4.24. Area 1 – PV generation and energy fed into the grid



Rys. 4.25. Obszar 2 – generacja PV i energia oddana do sieci

Fig. 4.25. Area 2 – PV generation and energy fed into the grid



Rys. 4.26. Obszar 3 – generacja PV i energia oddana do sieci

Fig. 4.26. Area 3– PV generation and energy fed into the grid

Wskaźnik autokonsumpcji (A_{kons}) jest definiowany jako (4.3):


$$A_{kons} = \frac{ER_{PV} - ER_{odd}}{ER_{PV}} * 100\% \quad (4.3)$$

gdzie:

ER_{PV} – energia rzeczywista wygenerowana w instalacji PV,

ER_{odd} – energia oddana (wprowadzona) do sieci dystrybucyjnej.

Na wykresie, na rys. 4.27 przedstawiono obliczony wskaźnik autokonsumpcji (ilość energii zużywanej na własne potrzeby w miejscu produkcji) na badanych obszarach.



Rys. 4.27. Porównanie wskaźników autokonsumpcji

Fig. 4.27. Comparison of self-consumption indicators

Literatura [33, 34, 35, 36] wskazuje, że stopień autokonsumpcji może wynosić od 20% do 60%, w zależności od rodzaju instalacji, zużycia energii w czasie rzeczywistym oraz zastosowania magazynów energii. Wiele jednak zależy od stopnia przewymiarowania instalacji PV w stosunku do potrzeb odbiorcy. Wskaźniki autokonsumpcji na badanych obszarach mieszczą się w przedziale od 17% do 26%, co jest zgodne z typowymi wartościami dla mikroinstalacji PV, które nie korzystają z magazynów energii. Wyższe wartości autokonsumpcji we Wrocławiu (szczytowy poziom 26% w 2023 roku) mogą wynikać z wyższego zapotrzebowania na energię w trakcie godzin szczytowej produkcji PV lub lepszego dopasowania profilu zużycia do profilu produkcji energii słonecznej. Niższe wartości autokonsumpcji (np. 17% w Krakowie w 2022 roku) mogą sugerować, że większa część wyprodukowanej energii jest oddawana do sieci, co może wynikać z niższego zużycia energii w czasie rzeczywistym w stosunku do generacji, szczególnie w godzinach o wysokiej produkcji PV. Badania [97] wskazują na niską autokonsumpcję w miesiącach letnich, o najwyższej generacji energii elektrycznej ze źródeł fotowoltaicznych. Ponadto wskaźnik autokonsumpcji będzie się różnił w zależności od tego, czy dane dotyczą obszaru miejskiego, wiejskiego czy mieszanego. Bez inwestycji w magazynowanie [98] bateryjne lub w inne formy energii, jak np. wodór, pojawi się problem nadmiaru energii i dojdzie do konieczności wyłączenia źródeł odnawialnych w celu zachowania bezpieczeństwa pracy KSE. Koszt zakupu magazynu energii, który znacząco zwiększa poziom autokonsumpcji jest wysoki i inwestycja nie ma rozsądnego okresu zwrotu. Oczekuje się jednak, że nowe programy dofinansowania do zakupu magazynu energii elektrycznej, a także spadek kosztów produkcji pozwolą na większą dostępność magazynów energii dla prosumentów w szczególności oraz również dla zwykłych odbiorców energii elektrycznej, którzy mogliby korzystać np. z taryfy dynamicznej.

5 PROGNOZY Z WYKORZYSTANIEM METODY BRUTTO

5.1 Mikrogeneracja – wyniki prognoz

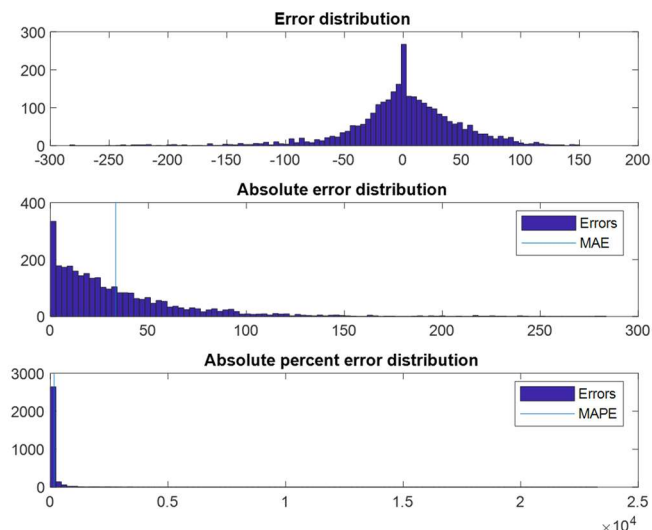
Na podstawie wyników przedstawionych w tabeli 5.1 można wyciągnąć kilka istotnych wniosków na temat jakości prognoz generacji fotowoltaicznej na różnych obszarach (pierwsze dwa znaki w nazwie oznaczają obszar, np. O1 – obszar 1 itd.) przy użyciu różnych modeli (Krzywa, XGBoost, Ensemble – model hybrydowy łączący wyniki prognoz z różnych modeli).

Tab. 5.1. Porównanie wyników prognoz generacji PV z różnych modeli na prognozowanych obszarach

Table 5.1. Comparison of PV generation forecast results from different models in the forecasted areas

Nr modelu	Nazwa modelu	R ²	MAE [MWh]	AE [MWh]	RMSE [MWh]	Odchylenie procentowe	ER [MWh]
1	O3PvEnsemble	0,81	37,7	111 459	53,8	28%	400 976
2	O3PvKrzywa	0,80	38,9	114 826	55,5	29%	400 976
3	O3PvXGBoost	0,85	33,3	98 312	48,0	25%	400 976
4	O2PvEnsemble	0,85	51,4	151 849	75,4	24%	636 496
5	O2PvKrzywa	0,83	56,6	167 067	80,1	26%	636 496
6	O2PvXGBoost	0,82	54,6	161 365	81,1	25%	636 496
7	O3PvEnsemble	0,86	88,0	259 725	129,3	24%	1 072 502
8	O3PvKrzywa	0,84	93,9	277 238	137,5	26%	1 072 502
9	O3PvXGBoost	0,84	93,9	277 298	140,6	26%	1 072 502

Na obszarze 3 wybrany został model O3PvXGBoost (Nr 3), który osiągnął najwyższą wartość $R^2=0,85$, co oznacza, że dobrze wyjaśnia zmienność danych. Model ma najniższy RMSE (48,0) i MAE (33,3), co wskazuje na najwyższą dokładność spośród modeli dla tego obszaru. Jednocześnie jego procentowe odchylenie (25%) jest najniższe, co oznacza mniejszy błąd względny w porównaniu z innymi modelami. Na wykresach, na rys. 5.1 przedstawiono analizę rozkładu błędów.




Rys. 5.1. Rozkład błędów generacji PV na obszarze 3

Fig. 5.1. Distribution of PV generation errors in the area 3

Pierwszy wykres przedstawia histogram błędów prognoz (różnica między rzeczywistą a prognozowaną wartościami). Widać, że błędy są w większości przypadków skoncentrowane wokół zera, co oznacza, że model nie jest obciążony systematycznym błędem (brak przesunięcia w jedną stronę). Rozkład błędów jest stosunkowo symetryczny, choć występują pewne skrajne wartości, co może oznaczać obecność błędów ekstremalnych (outlierów). Wartości te mogą wpływać na pogorszenie statystyk prognoz, np. RMSE. Na środkowym wykresie na histogramie przedstawiono rozkład błędów bezwzględnych (Absolute error distribution). Wartość błędu jest skumulowana głównie na niższych poziomach, a najwyższa liczba błędów jest w przedziale 0-50 MWh. Na wykresie widać również pionową linię, oznaczającą wartość MAE (Mean Absolute Error). To pokazuje, że większość błędów jest niższa od tej wartości, co oznacza, że model jest dość dokładny. Ostatni wykres przedstawia rozkład bezwzględnych, procentowych błędów. Większość prognoz ma bardzo niskie procentowe błędy, co wskazuje, że model jest precyzyjny w kontekście względnym. Wykres pokazuje, że istnieją pewne odległe wartości (prawy ogon rozkładu), co oznacza obecność kilku bardzo dużych, procentowych błędów. Te wartości mogą wynikać z nieprzewidzianych zmian w danych (np. ekstremalne dni pod względem generacji PV), błędy w prognozach meteorologicznych lub błędy w danych rzeczywistych.


Na wykresie, na rys. 5.2 przedstawiono błędy prognoz PV w podziale na godziny doby.



Rys. 5.2. Błędy procentowe generacji PV na obszarze 3 w podziale na godziny

Fig. 5.2. Percentage errors of PV generation in the area 3 divided into hours


Każde pudełko (boxplot) reprezentuje rozkład błędów dla konkretnej godziny. Środkowa linia w pudełku pokazuje medianę błędów prognozy dla danej godziny, czyli wartość środkową błędów. Jeśli linia ta znajduje się blisko zera, wówczas oznacza to, że prognozy są dobrze wyśrodkowane i nie ma dużych systematycznych błędów w tym okresie. Długość pudełka odzwierciedla rozrzut 50% błędów (od pierwszego do trzeciego kwartyla), czyli miarę zmienności błędów prognozy. Wąskie pudełko oznacza mniejszą zmienność prognozy, natomiast szerokie pudełko sugeruje większe rozproszenie błędów. Wąsy (whiskers) pokazują rozrzut danych do wartości maksymalnej i minimalnej, bez uwzględnienia wartości odstających. Dłuższe wąsy oznaczają większą zmienność błędów prognoz w danej godzinie. Czerwone krzyżyki reprezentują wartości odstające, czyli przypadki, w których błędy prognozy znacząco odbiegają od typowych wyników. Najniższe błędy procentowe prognoz pojawiają się w środku dnia (godziny 9-16), co sugeruje, że model najlepiej radzi sobie z prognozowaniem generacji PV w godzinach największego nasłonecznienia, kiedy warunki są bardziej przewidywalne. Jeśli jednak spojrzymy na wolumeny odchyień, to sytuacja jest odwrotna. Jest to spowodowane dzieleniem odchylenia przez mały mianownik tj. niską wartość danych rzeczywistych. Większe rozrzuty i większa liczba outlierów obserwuje się wcześniej rano (np. godzina 5) oraz późnym popołudniem (godzina 19), co sugeruje większą zmienność i trudności w prognozowaniu generacji PV w tych porach. Może to być spowodowane specyficznymi warunkami meteorologicznymi, a także początkowym wzrostem oraz spadkiem nasłonecznienia. W tych godzinach występuje wiele wartości odstających. Wszystko powyżej sugeruje, że prognozy są znacznie mniej stabilne i bardziej narażone na duże błędy w tych godzinach. Analogiczną analizę odchyień można przeprowadzić dla danych w podziale na miesiące roku, co przedstawiono na wykresie poniżej (rys. 5.3).



Rys. 5.3. Błędy procentowe generacji PV na obszarze 3 w podziale na miesiące

Fig. 5.3. Percentage errors of PV generation in the area 3 divided into months

W miesiącach styczniu i lutym prognozy są znacznie mniej stabilne i bardziej narażone na duże błędy. Dzień jest krótki, ilość promieniowania słonecznego, która dociera do paneli fotowoltaicznych jest niska, występuje większe zachmurzenie i większa jest ilość aerozoli w powietrzu. Są to niekorzystne warunki dla generacji fotowoltaicznej oraz dla jej przewidywania. Wykres na rys. 5.4 przedstawia dwutygodniową prognozę zapotrzebowania na energię elektryczną wraz z danymi rzeczywistymi oraz odchyleniami w okresie od 30.06.2024.

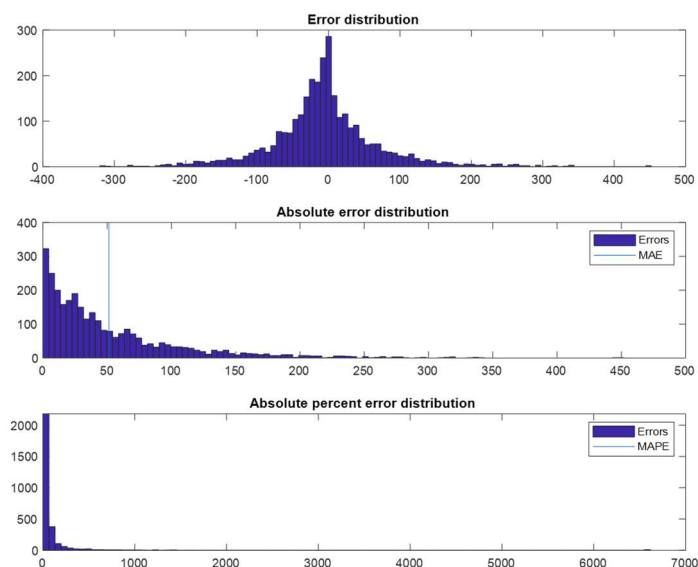


Rys. 5.4. Dwutygodniowa prognoza i wykonanie rzeczywiste oraz odchylenia prognozy na obszarze 3

Fig. 5.4. Two-week forecast and actual performance and forecast deviations in the area 3

Na obszarze 2 wybrany został model O2PvEnsemble (nr 4), który osiągnął najwyższą wartość $R^2=0,85$, co czyni go najprecyzyjniejszym w wyjaśnianiu zmienności danych na tym obszarze. Model charakteryzuje się najniższym RMSE (75,4) oraz MAE (51,4), co


świadczy o najlepszej dokładności prognozy w tym regionie, w porównaniu z innymi testowanymi modelami.



Rys. 5.5. Rozkład błędów generacji PV na obszarze 2

Fig. 5.5. Distribution of PV generation errors in the area 2


Rozkład błędów przedstawiony na wykresie 5.5 pozwala zakładać prawidłowość odwzorowania generacji przez model.



Rys. 5.6. Błędy procentowe generacji PV na obszarze 2 w podziale na godziny

Fig. 5.6. Percentage errors of PV generation in the area 2, divided into hours


Szerokie pudełko na wykresie 5.6 dla godzin 4-5 i 18-19 potwierdza trudność ich dokładnego prognozowania.



Rys. 5.7. Błędy procentowe generacji PV na obszarze 2 w podziale na miesiące

Fig. 5.7. Percentage errors of PV generation in the area 2, divided into months

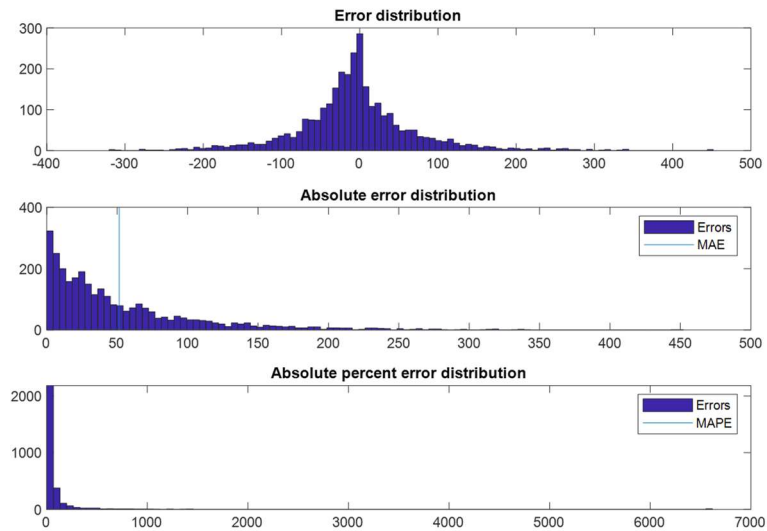
Analogiczna sytuacja powtarza się na obszarze Wrocław – szerokie pudełko na wykresie, na rys. 5.7 dla stycznia i lutego potwierdza trudność ich dokładnego prognozowania.



Rys. 5.8. Dwutygodniowa prognoza i wykonanie rzeczywiste oraz odchylenia prognozy na obszarze Wrocław


Fig. 5.8. Two-week forecast and actual performance and forecast deviations in the Wrocław area

Na obszarze 1 wybrany został model O1PvEnsemble (Nr 7), który ma najwyższą wartość $R^2=0,86$ i najniższe wartości MAE (88,0) oraz RMSE (129,3), co wskazuje na jego przewagę w dokładności prognozowania na tym obszarze.




Rys. 5.9. Rozkład błędów generacji PV na obszarze 1

Fig. 5.9. Distribution of PV generation errors in the area 1




Rys. 5.10. Błędy procentowe generacji PV na obszarze 1 w podziale na godziny

Fig. 5.10. Percentage errors of PV generation in the area 1, divided into hours



Rys. 5.11. Błędy procentowe generacji PV na obszarze 1 w podziale na miesiące

Fig. 5.11. Percentage errors of PV generation in the area 1, divided into months



Rys. 5.12. Dwutygodniowa prognoza i wykonanie rzeczywiste oraz odchylenia prognozy na obszarze 1

Fig. 5.12. Two-week forecast and actual performance and forecast deviations in the area 1

Na przedstawionych wykresach (rys. 5.9, rys. 5.10, rys. 5.11 i rys 5.12) zaobserwować można analogiczną sytuację do wcześniej prezentowanych wykresów dla obszarów 2 i 3.

5.2 Zapotrzebowanie brutto – wyniki prognoz

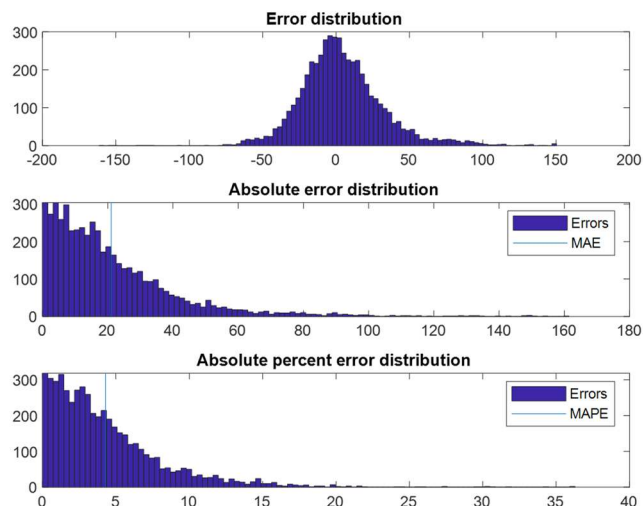
Na podstawie przedstawionych w tabeli 5.2 wyników można porównać prognozy zapotrzebowania brutto na różnych obszarach. Pierwsze dwa znaki w nazwie oznaczają obszar, kolejne dwie Zb – zapotrzebowanie brutto, a następne nazwę modelu. Do porównania wybrano model XGBoost, metodę Naiwną oraz model hybrydowy, łączący wyniki prognoz z różnych modeli – Ensemble.

Tab. 5.2. Porównanie wyników prognoz zapotrzebowania brutto z różnych modeli na prognozowanych obszarach

Table 5.2. Comparison of gross demand forecast results from different models in the forecasted areas

Nr modelu	Nazwa modelu	R ²	MAE [MWh]	AE [MWh]	RMSE [MWh]	Odchylenie procentowe	ER [MWh]
1	O3ZbEnsemble	0,94	21,03	107 523	29	4,2%	2 531 188
2	O3ZbXGBoost	0,92	24,24	123 917	32	4,9%	2 531 188
3	O3ZbNaiwna	0,86	30,23	154 527	43	6,1%	2 531 188
4	O2ZbEnsemble	0,91	45,23	231 207	62	5,5%	4 189 385
5	O2ZbXGBoost	0,90	46,50	237 696	64	5,7%	4 189 385
6	O2ZbNaiwna	0,82	55,76	285 046	85	6,8%	4 189 385
7	O1ZbEnsemble	0,93	57,01	291 420	76	4,9%	5 975 166
8	O1ZbXGBoost	0,93	57,80	295 463	78	4,9%	5 975 166
9	O1ZbNaiwna	0,87	70,67	361 240	102	6,0%	5 975 166


Odchylenie prognoz od danych rzeczywistych waha się od 4,2% do 5,5%. Najlepsze wyniki na każdym obszarze osiąga model hybrydowy Ensemble, a najgorsze – metoda naiwna, która służy jako odniesienie. Rysunek 5.13 przedstawia trzy histogramy. Górny wykres prezentuje histogram błędów prognozy. Rozkład wydaje się być normalny, skupiony wokół 0, ze stosunkowo symetrycznym rozrzutem. Oś x przedstawia wartości błędów, podczas gdy oś y – częstotliwość występowania dla każdego przedziału błędów. Środkowy wykres przedstawia histogram błędów bezwzględnych. Wartości błędów mieszczą się głównie w zakresie od 0 do 50, ze stromym spadkiem w miarę wzrostu błędu. Średni błąd bezwzględny wynosi nieco ponad 20 MWh. Dolny wykres przedstawia histogram, który pokazuje średni błąd bezwzględny procentowy (MAPE). Zakres wydaje się tutaj węższy, a większość wartości jest skupiona między 0 a 10, przy średnim błędzie MAPE poniżej 5%.



Rys. 5.13. Rozkład błędów zapotrzebowania brutto na obszarze 3

Fig. 5.13. Distribution of gross demand errors in the area 3

Wykres 5.14 przedstawia autokorelację reszt prognozy w zależności od opóźnienia. Interpretacja tego wykresu może dostarczyć informacji na temat tego, czy reszty (czyli błędy prognozy) są ze sobą powiązane w czasie.



Rys. 5.14. Autokorelacja reszt modelu Ensemble zapotrzebowania brutto na obszarze 3

Fig. 5.14. Autocorrelation of residuals of the Ensemble model of gross demand in the 3 area

Najwyższa wartość autokorelacji (około 1) przy opóźnieniu 0 oznacza, że reszty są idealnie ze sobą skorelowane (co jest normalne przy opóźnieniu 0). Niska autokorelacja reszt jest pożądana, ponieważ oznacza, że model dobrze prognozuje zmienne i nie pozostawia żadnych systematycznych wzorców błędów. W badanych modelach każdy wykazywał wysokie poziomy autokorelacji do 72 opóźnienia. To jest dość częsty problem w tego typu modelach, zwłaszcza gdy mamy do czynienia z szeregami

czasowymi. Zapotrzebowanie na energię elektryczną często wykazuje sezonowe i cykliczne wzorce. Istotny wpływ mają również warunki pogodowe lub awarie sieciowe, które jest trudno przewidzieć. Jeśli model nie uwzględni w pełni tych wzorców, wówczas reszty mogą wykazywać autokorelację.

5.3 Suma składowych – wyniki prognoz


Na podstawie wyników przedstawionych w tabeli 5.3, można porównać metodę prognozowania zapotrzebowania, opierając się na profilu brutto i generacji PV z modelem referencyjnym, prognozującym na danych netto w różnych obszarach.

Tab. 5.3. Porównanie wyników prognoz brutto z modelem referencyjnym na obszarach

Table 5.3. Comparison of gross forecast results with the reference model in the areas

Nr modelu	Nazwa modelu	R ²	MAE [MWh]	AE [MWh]	RMSE [MWh]	Odch. proc.	ER [MWh]
1	O3ZnXGBoost	0,85	40,35	206 262	60	9,7%	2 128 152
2	O3ZnBrutto	0,91	31,95	163 309	46	7,7%	2 128 152
3	O2ZnXGBoost	0,90	55,58	284 143	77	8,0%	3 552 273
4	O2ZnBrutto	0,91	52,37	267 710	71	7,5%	3 552 273
5	O1ZnXGBoost	0,91	77,68	397 107	116	8,1%	4 901 400
6	O1ZnBrutto	0,94	68,92	352 302	98	7,2%	4 901 400


Jako model referencyjny został wybrany XGBoost, który na danych zapotrzebowania netto był modelem o najniższych odchyleniach. Na każdym z badanych obszarów, metoda brutto (zapotrzebowania brutto i generacja PV) osiągała lepsze wyniki. Szczególnie duża różnica była na obszarach 1 i 3. Mniejsza poprawa była na obszarze 2.



Rys. 5.15. Dwutygodniowa prognoza i wykonanie rzeczywiste zapotrzebowania netto oraz odchylenia na obszarze 3


Fig. 5.15. Two-week forecast and actual execution of net demand and deviations in the area 3

Na wykresach (rys. 5.15, 5.16 i 5.17) można zaobserwować prawidłowe odwzorowanie cykli dobowych i tygodniowych przez metodę brutto. Prawidłowo również odwzorowano cykle dobowe generacji fotowoltaicznej, która jest silnie zależna od natężenia promieniowania słonecznego i powoduje obniżenie zapotrzebowania w godzinach, w których słońce jest nad horyzontem.



Rys. 5.16. Dwutygodniowa prognoza i wykonanie rzeczywiste zapotrzebowania netto oraz odchylenia na obszarze 2


Fig. 5.16. Two-week forecast and actual execution of net demand and deviations in the area 2




Rys. 5.17. Dwutygodniowa prognoza i wykonanie rzeczywiste zapotrzebowania netto oraz odchylenia na obszarze 1

Fig. 5.17. Two-week forecast and actual execution of net demand and deviations in the area 1


Na wykresach (rys. 5.18, 5.19 i 5.20) przedstawiono błędy zapotrzebowania netto w podziale na obszary i godziny.



Rys. 5.18. Błędy procentowe zapotrzebowania netto na obszarze 3 w podziale na godzinę
 Fig. 5.18. Percentage errors of net demand in the area 3 by hour



Rys. 5.19. Błędy procentowe zapotrzebowania netto na obszarze 2 w podziale na godziny
 Fig. 5.19. Percentage errors of net demand in the area 2, divided into hours



Rys. 5.20. Błędy procentowe zapotrzebowania netto na obszarze 1 w podziale na godziny

Fig. 5.20. Percentage errors of net demand in the area 1, broken down by hours

Rozkład błędów na każdym z badanych obszarów przedstawia tę samą zależność – błędy w godzinach od 1 do 5 i od 19 do 24 są na niskich poziomach, z niewielkim rozrzutem. Od godziny 6 błędy zaczynają rosnać, osiągając szczyt w godzinie 13, a następnie maleją do godziny 18. Taka prawidłowość odwzorowuje zmienną generację fotowoltaiczną, która jest przyczyną niedokładności prognoz zapotrzebowania netto.

5.4 Wybór prognoz meteorologicznych


Dla porównania prognoz natężenia promieniowania słonecznego – GHI i danych rzeczywistych generacji PV oraz danych rzeczywistych o oddaniu energii elektrycznej do sieci dystrybucyjnej przez prosumentów, użyto współczynnika determinacji R^2 . Współczynnik korelacji zmiennej objaśnianej i zmiennej objaśniającej określa, czy istnieje liniowa zależność pomiędzy jedną a drugą zmiennymi. Badane były zarówno dostawy prognoz komercyjnych (zakupionych przez spółkę obrotu), tj. DTN i ICM, jak i niekomercyjnych – pozostali dostawcy. Opis modeli przedstawiono w tabeli 5.4.

Tab. 5.4. Numeracja różnych modeli pogodowych, wykorzystanych w badaniu korelacji pomiędzy generacją PV a natężeniem promieniowania słonecznego

Tab. 5.4. Numbers of different weather models used in the study of correlation between PV generation and solar radiation intensity

Numer modelu	Nazwa modelu
Model 1	DTN (prognoza punktowa)
Model 2	DTN średnia ważona (prognoza uśredniona dla całego obszaru)
Model 3	IMGW (prognoza punktowa)
Model 4	ICM (prognoza punktowa)
Model 5	ICON (prognoza punktowa)
Model 6	GFS (prognoza punktowa)
Model 7	METEOFRANCE (prognoza punktowa)
Model 8	GEM (prognoza punktowa)


W większości okresów model komercyjny dawał wyższy wynik korelacji niż prognozy niekomercyjne. Instalacje fotowoltaiczne rozłożone są nierównomiernie na obszarze działalności spółki sprzedażowej. Konieczna zatem była agregacja prognoz meteorologicznych z różnych punktów. Z uwagi na to, że dane zapotrzebowania agregowane są w podziale na obszary, również zagregowane zostały dane dotyczące energii elektrycznej instalacji prosumenckich. Prognozy meteorologiczne wybranych stacji na prognozowanym obszarze zostały uśrednione z wagą mocy PV zainstalowanej na danym obszarze.



Rys. 5.21. Korelacja pomiędzy energią oddaną do sieci przez prosumentów a prognozą GHI różnych dostawców prognoz meteorologicznych

Fig. 5.21. Correlation between the energy fed into the grid by prosumers and the GHI forecast of different weather forecast providers

Na powyższym wykresie (rys. 5.21) przedstawiona została korelacja pomiędzy prognozami natężenia promieniowania słonecznego a oddaniem energii elektrycznej do sieci przez prosumentów przyłączonych do spółki obrotu. Badanie zostało przeprowadzone w ograniczonym zakresie, na podstawie prognoz komercyjnych oraz prognoz dostępnych niekomercyjnie. Najwyższą korelację osiągnęła prognoza komercyjna dla punktu o współrzędnych geograficznych miasta Kraków. Kolejna pod względem zdolności do objaśnienia była również komercyjna prognoza DTN, tym razem uśredniona mocą zainstalowaną mikroinstalacji na danym obszarze. Kolejne miejsca zajęły prognozy IMGW, ICM oraz ICON.




Rys. 5.22. Korelacja pomiędzy generacją PV a prognozą GHI różnych dostawców prognoz meteorologicznych

Fig. 5.22. Correlation between PV generation and GHI forecast of different weather forecast providers

Na powyższym wykresie (rys. 5.22) przedstawione zostało analogiczne porównanie jak na rys. 5.21, z tym że prognozy GHI badano, czy i jak są skorelowane z szacowaną

generacją fotowoltaiczną na badanym obszarze. W tym przypadku pierwsze dwa miejsca należą do komercyjnej prognozy DTN, a trzecie miejsce zajmują prognozy IMGW oraz ICON. W sytuacji braku rzeczywistych pomiarów GHI, najlepszym podejściem jest porównanie prognoz GHI przez ich wpływ na generację mocy PV. Korzystając z dostępnych danych dotyczących generacji PV, można ocenić dokładność prognoz GHI na podstawie prognozowanej i rzeczywistej produkcji energii z modułów PV. W tym celu przeprowadzono test, wykorzystując funkcję multcomparep w Matlab. Funkcja służy do przeprowadzenia analizy wariancji (ANOVA).



Rys. 5.23. Analiza wariancji ANOVA dla generacji PV i prognoz GHI różnych dostawców prognoz meteorologicznych


Fig. 5.23. ANOVA for PV generation and GHI forecasts from different weather forecast providers

Na wykresie, na rys. 5.23 zaznaczono grupę ER (generacja fotowoltaiczna), która stanowi grupę referencyjną (rzeczywiste dane). Jej wynik jest pokazany jako niebieski punkt, z niebieską linią reprezentującą przedział ufności. Prognozy od różnych dostawców są pokazane na wykresie jako czerwone kółka z poziomymi liniami, które reprezentują średnią wartość prognozy oraz odpowiednie przedziały ufności. Czerwone kółka i poziome linie przedstawiają średnią dla każdej prognozy oraz przedziały ufności dla tych średnich. Prognozy, których przedziały ufności nie pokrywają się z przedziałem dla ER są uznawane za statystycznie różne od grupy ER. Na wykresie, na rys. 5.23 widać, że 6 prognoz ma średnie znacząco różniące się od ER, ponieważ ich przedziały nie obejmują wartości średniej grupy ER. Prognoza DTN wykonanie GHI (oznaczona szarym kolorem) nie różni się statystycznie od ER, co oznacza, że jest najbliższa rzeczywistości lub wartościom referencyjnym. W tabeli 5.5 przedstawiono wyniki z analizy anova.

Tab. 5.5. Wyniki analizy anova dla generacji PV i prognoz GHI różnych dostawców prognoz meteorologicznych
 Tab. 5.5. Results of anova analysis for PV generation and GHI forecasts from different weather forecast providers

ANOVA Table					
Source	SS	df	MS	F	Prob>F
Groups	1.82127e+07	7	2601813.9	17.09	1.11887e-22
Error	2.44674e+09	16072	152236		
Total	2.46495e+09	16079			


Wysoka wartość F sugeruje, że zmienność między grupami jest znacznie większa niż wewnątrz grup, co wskazuje na istotne statystycznie różnice. Prob>F to p-wartość dla testu F. Bardzo mała p-wartość (znacznie poniżej 0.05) oznacza, że istnieją statystycznie istotne różnice między grupami, czyli średnie wartości prognoz (ER i Prognozy 1-7) istotnie się różnią.



Rys. 5.24. Wyniki testu anova dla prognoz generacji PV na podstawie prognoz GHI różnych dostawców
 Fig. 5.24. Results of anova test for PV generation forecasts based on GHI forecasts from different suppliers

Wykres pudełkowy (rys. 5.24) przedstawia rozkład wyników dla ER oraz poszczególnych prognoz GHI (prognozy od dostawców: DTN, IMGW, ICON, GFS, ICM). Środkowa linia w pudełku oznacza medianę prognoz. Pudełko oznacza zakres od 1. do 3. kwartyła, reprezentujący 50% danych. Wąsy oznaczają maksymalny zakres danych bez wartości odstających. ER ma pudełko o nieco mniejszej rozpiętości niż większość prognoz, co oznacza mniejsze rozproszenie wartości. Prognozy „IMGW dla Krakowa”, „GFS dla Krakowa”, „ICM dla Krakowa” oraz „ICON dla Krakowa” wykazują podobną medianę, jednak wszystkie poza „IMGW dla Krakowa” mają większe rozpiętości, co sugeruje większą zmienność prognoz. Wszystkie prognozy pokazują znaczne rozproszenie wartości (długie wąsy), co może wskazywać na mniej precyzyjne prognozy. Prognoza „IMGW dla Krakowa” ma stosunkowo małe pudełko z niską medianą, co sugeruje, że

jest bardziej zwarte, a rozrzut wyników jest mniejszy niż w innych przypadkach. Bardzo niska p-wartość sugeruje, że różnice między prognozami są statystycznie istotne. Na podstawie wykresu pudełkowego (rys. 5.24) można ocenić, że prognoza „ICON dla Krakowa” ma największą zmienność, a prognozy „DTN dla Krakowa” i „DTN Średnia ważona na obszarze” mają wartości zbliżone do wartości ER. Wskazuje to, że istnieją istotne różnice w dokładności poszczególnych modeli prognozowania GHI dla Krakowa, a niektóre modele (np. DTN) mogą dawać stabilniejsze wyniki. Na wykresie poniżej (rys. 5.25) przedstawione zostały odchylenia prognoz generacji fotowoltaicznej, które obliczono na podstawie prognoz GHI różnych dostawców.



Rys. 5.25. Porównanie odchyłeń prognoz generacji PV, obliczonych na podstawie prognoz GHI różnych dostawców prognoz meteorologicznych

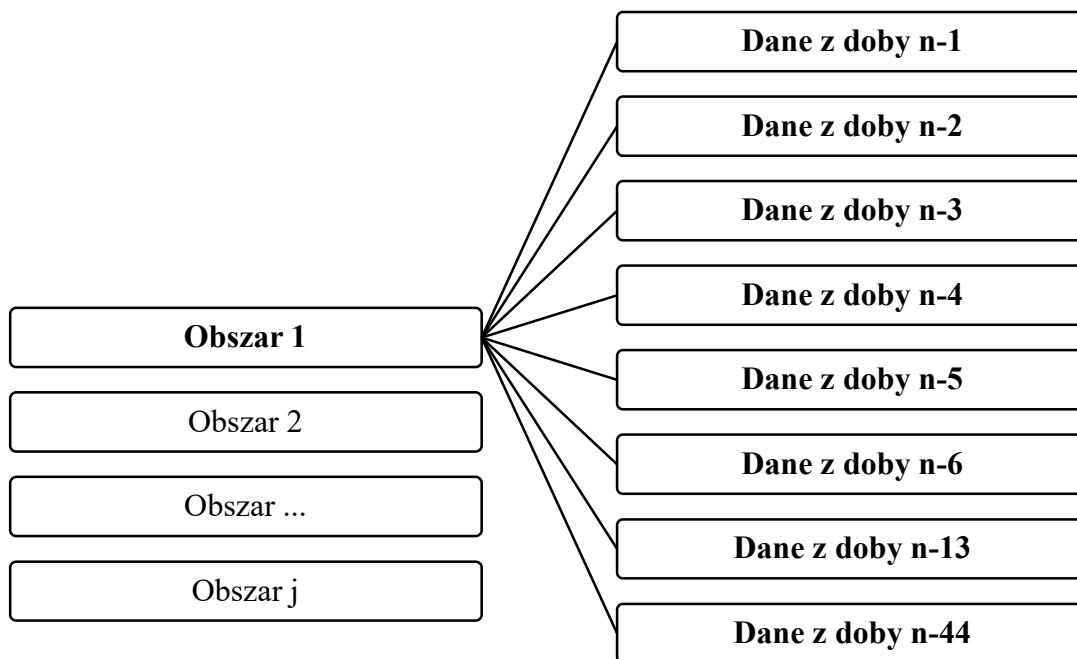
Fig. 5.25. Comparison of PV generation forecast deviations calculated based on GHI forecasts from different meteorological forecast providers

Z przedstawionego wykresu wynika, że prognozy wyliczone na danych rzeczywistych GHI mają najmniejsze odchylenia. Jest to potwierdzenie prawidłowości i jakości danych rzeczywistych, które DTN jako jedyny dostawca z powyższych jest w stanie dostarczyć. Prognozy ICON, które według wykresu z rys. 5.25 mogły być najlepsze jest na czwartym miejscu, za modelami komercyjnymi DTN. Dla dwóch najlepszych prognoz, tj. DTN prognoza ważona (model pierwszy) i DTN prognoza punktowa (model drugi) wykonany został test Diebolda-Mariano. Wynik testu wyniósł -10.2955. Ujemna wartość sugeruje, że pierwszy model (referencyjny) ma mniejsze błędy prognozy niż drugi model. P-value w tym teście jest równe 0, co oznacza, że wynik testu jest istotny statystycznie. Występuje zatem podstawa do odrzucenia hipotezy zerowej, która mówi, że oba modele mają podobną jakość prognozy. P-value na poziomie 0 wskazuje, że istnieje bardzo niskie prawdopodobieństwo, że różnice w błędach prognozy między modelami są wynikiem przypadku, a nie rzeczywistych różnic między modelami. Ten sam test wykonany dla prognozy ICON dla Krakowa (model pierwszy) i DTN średnia ważona (model drugi) wskazał na wyższość modelu drugiego. Wynik testu wyniósł 6,7414, a P-value również był równy 0.

5.5 Zmienność danych rzeczywistych zapotrzebowania na energię elektryczną

Podstawą do przygotowania w dobie n prognozy zapotrzebowania na dobę $n+1$ są historyczne, zagregowane dane rzeczywiste odbiorców na danym obszarze. Są to regiony o wielkości województwa i zawierają różne grupy klientów ze wszystkich grup taryfowych. Metoda agregacji wynika z możliwości i zasad udostępniania danych przez operatorów systemów dystrybucyjnych oraz operatora systemu przesyłowego. OSP w współpracy z OSD wyznaczają i udostępnianiu dane pomiarowych dla uczestników rynku energii elektrycznej. Zasady udostępniania danych określone zostały w instrukcji ruchu i eksploatacji sieci dystrybucyjnej oraz warunkach dotyczących bilansowania. Ten drugi dokument określa terminy udostępniania danych. Najwcześniej (w dobie $n+1$) udostępniane są wstępne dane pomiarowe, tj. niezweryfikowane dane, pozyskane w trakcie okresu rozliczeniowego z układów pomiarowych i pomiarowo-rozliczeniowych, które nie służą do rozliczeń, a pozyskane są jedynie w celu prowadzenia działalności operatorskiej przez OSD. W dobie $n+4$ wyznaczane i weryfikowane są dane w trybie dobowym podstawowym. Dane wystawiane comiesięcznie, w 5. dobie roboczej miesiąca m za kolejne dekady miesiąca m , miesiąc $m-1$, $m-2$, $m-4$ i $m-15$ są danymi korygującym. Umożliwiają skorygowanie wyznaczonych wcześniej wielkości ER.

Z uwagi na możliwe udostępnienie błędnych danych, konieczna jest kontrola danych wejściowych do modeli automatycznie generujących prognozy. Dla modeli prognostycznych kluczowe znaczenia ma prawidłowość danych wejściowych. Nie mniej istotne jest, żeby dane były możliwe szybko udostępniane, co pozwala na uwzględnienie najnowszych trendów, które się ujawniają. Żeby możliwe było sprawdzenie, w jaki sposób OSD dokonuje korekty oraz kiedy dane są wiarygodne, opracowano mechanizm archiwizacji danych. Zakładając, że n to doba wykonywania prognozy na dobę $n+1$, sprawdzane były dane zapisane dla dób poprzedzających dobę n , zgodnie z poniższym schematem – rys. 5.26.



Rys. 5.26. Schemat archiwizacji danych zapotrzebowania w celu zbadania zmienności w udostępnianych przez OSD danych rzeczywistych do prognozowania

Fig. 5.26. Scheme of demand data archiving to examine the variability of actual data provided by the DSO for forecasting

Wyniki analiz w podziale na lata 2022, 2023 i 2024 przedstawiono w poniższych tabelach (tab. 5.6, 5.7 i 5.8). Odchylenie procentowe zostało obliczone w odniesieniu do średniego zapotrzebowania w tym samym okresie. Z oczywistych względów im dane są starsze, tym ich odchylenie od danych rzeczywistych jest najmniejsze. Ta reguła sprawdza się do doby n-13. W przypadku doby n-44 OSD dokonuje korekt, które dosyć często zwiększają odchylenie od danych rzeczywistych. Regułą jest, że dane z doby n-1, n-2 oraz n-3 są błędne i nie należy ich uwzględniać w wyliczeniach modeli automatycznych.

Tab. 5.6. Porównanie odchyleń danych rzeczywistych w 2024 roku, udostępnianych z różnym opóźnieniem, w podziale na obszar Kraków, Wrocław i Gliwice

Tab. 5.6. Comparison of deviations of actual data in 2024, made available with different delays, divided into the areas of Kraków, Wrocław and Gliwice

Tryb zapisu danych	Obszar Kraków		Obszar Wrocław		Obszar Gliwice	
	Średnie odchylenie w MW	Średnie odchylenie w %	Średnie odchylenie w MW	Średnie odchylenie w %	Średnie odchylenie w MW	Średnie odchylenie w %
n-1	153	17%	131	20%	73	18%
n-2	89	10%	132	20%	55	14%
n-3	151	16%	154	23%	74	18%

n-4	29	3%	27	4%	17	4%
n-5	29	3%	26	4%	15	4%
n-6	28	3%	25	4%	15	4%
n-13	27	3%	23	3%	16	4%
n-44	27	3%	65	10%	16	4%

Tab. 5.7. Porównanie odchyłeń danych rzeczywistych w 2023 roku, udostępnianych z różnym opóźnieniem, w podziale na obszar Kraków, Wrocław i Gliwice

Tab. 5.7. Comparison of deviations of actual data in 2023, made available with different delays, divided into the areas of Kraków, Wrocław and Gliwice

Tryb zapisu danych	Obszar Kraków		Obszar Wrocław		Obszar Gliwice	
	Średnie odchylenie w MW	Średnie odchylenie w %	Średnie odchylenie w MW	Średnie odchylenie w %	Średnie odchylenie w MW	Średnie odchylenie w %
n-1	188	18%	117	15%	146	33%
n-2	78	7%	100	13%	39	9%
n-3	96	9%	104	13%	42	10%
n-4	23	2%	8	1%	7	2%
n-5	23	2%	8	1%	7	2%
n-6	24	2%	9	1%	7	2%
n-13	25	2%	11	1%	8	2%
n-44	33	3%	19	2%	13	3%


Tab. 5.8. Porównanie odchyłeń danych rzeczywistych w 2022 roku, udostępnianych z różnym opóźnieniem, w podziale na obszar Kraków, Wrocław i Gliwice

Table 5.8. Comparison of deviations of actual data in 2022, made available with different delays, divided into the areas of Kraków, Wrocław and Gliwice

Tryb zapisu danych	Obszar Kraków		Obszar Wrocław		Obszar Gliwice	
	Średnie odchylenie w MW	Średnie odchylenie w %	Średnie odchylenie w MW	Średnie odchylenie w %	Średnie odchylenie w MW	Średnie odchylenie w %
n-1	566	54%	260	31%	267	67%
n-2	72	7%	126	15%	53	13%
n-3	261	25%	196	24%	57	14%
n-4	21	2%	9	1%	20	5%


n-5	21	2%	10	1%	17	4%
n-6	22	2%	10	1%	16	4%
n-13	22	2%	11	1%	17	4%
n-44	42	4%	16	2%	17	4%

Na poniższych wykresach (rys. 5.27, 5.28 i 5.29) przedstawiono odchylenia danych udostępnianych przez OSD w poszczególnych dobach, uśrednione w godzinach doby.




Rys. 5.27. Średnie godzinowe odchylenie danych udostępnianych przez OSD na obszarze 1

Fig. 5.27. Average hourly deviation of data provided by OSD in the area 1



Rys. 5.28. Średnie godzinowe odchylenie danych udostępnianych przez OSD na obszarze 2

Fig. 5.28. Average hourly deviation of data provided by OSD in the area 2



Rys. 5.29. Średnie godzinowe odchylenie danych udostępnianych przez OSD na obszarze 3

Fig. 5.29. Average hourly deviation of data provided by OSD in the area 3

Na podstawie analizy wizualnej wykresów można założyć, że nie istnieje żadna zależność wskazująca na godziny mniej lub bardziej obciążone błędami systematycznymi. Zazwyczaj odchylenia są podobne, niezależnie od godziny doby, a ich poziom zmienia się jedynie w zależności od trybu wystawienia danych.

5.6 Koszty odchyłeń prognoz

Istnieją dwa rodzaje niedokładności prognoz – niedoszacowanie oraz przeszacowanie prognozy. Oba rodzaje odchylenia prognozy od danych rzeczywistych są niekorzystne i generują koszty, które spółka obrotu musi wkalkulować w cenę sprzedaży

energii elektrycznej do odbiorców [135]. O niedoszacowaniu mówi się wtedy, kiedy prognozowane zapotrzebowanie jest niższe od rzeczywistego, co można zapisać w postaci wzoru (5.1):

$$E_R - E_D > 0 \quad (5.1)$$

Przypadek przeszacowania występuje, gdy prognozowane zapotrzebowanie jest wyższe od rzeczywistego, co można zapisać wzorem (5.2):

$$E_R - E_D < 0 \quad (5.2)$$

gdzie:

E_R – energia rzeczywista (wykonane zapotrzebowanie),

E_D – energia deklarowana (prognoza zapotrzebowania).

Niedokładności prognoz mogą prowadzić do zwiększenia kosztów działalności uczestnika rynku, przez zwiększenie kosztów bilansowania. Właściwie wdrożony system zarządzania ryzykiem handlowym wymaga, aby sprzedawcy energii elektrycznej bilansowali swój portfel na RDN. Wszystkie odchylenia prognoz prowadzą do konieczności zakupu lub sprzedaży energii po cenach RB, które mogą być znacznie wyższe lub niższe od cen RDN. Koszt niedokładności prognoz można obliczyć na kilka sposobów. W niniejszej dysertacji skupiono się na jednej z popularniejszych metod, jaką jest metoda kosztów bilansowania. Polega ona na obliczeniu różnicy między cenami RDN a cenami rynku bilansującego. Metoda kosztów bilansowania jest prostym i efektywnym sposobem obliczania kosztów niedokładności prognoz zapotrzebowania na energię elektryczną [135]. Jest ona łatwa do zrozumienia i wdrożenia, a także zapewnia dokładny pomiar kosztów.

$$K_B = (P_{RB} - P_{RDN}) * (E_R - E_D) \quad (5.3)$$

gdzie:

K_B – koszt bilansowania,

P_{RB} – cena RB,

P_{RDN} – cena RDN.

W tabeli 5.9 przedstawione zostały obliczenia kosztów bilansowania prognoz modelu brutto oraz modelu referencyjnego. W każdym przypadku odnotowano poprawę wyniku finansowego w badanym okresie.

Tab. 5.9. Porównanie kosztu bilansowania metody brutto i modelu referencyjnego

Table 5.9. Comparison of the balancing cost of the gross model and the reference model

Obszar	Poprawa wyniku finansowego według metody brutto [zł]
Obszar 1	2 135 948
Obszar 2	581 923
Obszar 3	2 954 537

Jeden z obszarów uzyskał najwyższą poprawę wyniku finansowego (80%), co sugeruje, że metoda brutto na tym obszarze działa najefektywniej. Pozostałe obszary osiągnęły mniejszą poprawę wyniku finansowego (14% i 36%), co może wskazywać na mniejszą skuteczność metody brutto na tych regionach. Najwyższa poprawa wyniku może być związana z wysokim udziałem generacji fotowoltaicznej w zapotrzebowaniu oraz niższym udziałem klientów ze stabilnym profilem zapotrzebowania w trakcie dnia (np. przemysł energochłonny). W przypadku pozostałych obszarów udział generacji fotowoltaicznej jest również znaczący, ale jest to kompensowane przez większy wolumen odbiorców przemysłowych.

6 DODATKOWE ZASTOSOWANIA METODY BRUTTO

Zarówno w horyzoncie krótkoterminowym, jak i długoterminowym prognozy metodą brutto mogą pomóc w identyfikacji i wykorzystaniu arbitrażowych możliwości na rynku. W horyzoncie krótkoterminowym prognozy mogą pomóc w identyfikacji i wykorzystaniu krótkotrwałych, arbitrażowych możliwości na rynku. Prognozy pozwalają na optymalizację zakupu i sprzedaży energii na rynku spot i rynku dnia bieżącego, biorąc pod uwagę wahania cen i dostępność energii odnawialnej. Dzięki dokładniejszym prognozom można lepiej ocenić ryzyko związane z wahaniami cen energii i podejmować odpowiednie działania hedgingowe (kontraktowanie energii z wyprzedzeniem). Prognozowanie różnic między produkcją fotowoltaiczną na rynkach dnia następnego i bieżącym może zoptymalizować strategie sprzedaży, zwiększając zyski przez skuteczne wykorzystanie spreadów (różnic) cenowych w procesach decyzyjnych [81]. Jak wskazują autorzy [82], strategia poprawia przychody o prawie 20%. Inni autorzy [83] wskazują, że ich narzędzie prognostyczne może zmniejszyć średni błąd bezwzględny odpowiednio do 31,96% i 32,45% dla prognoz rynku dnia następnego i rynku dnia bieżącego.

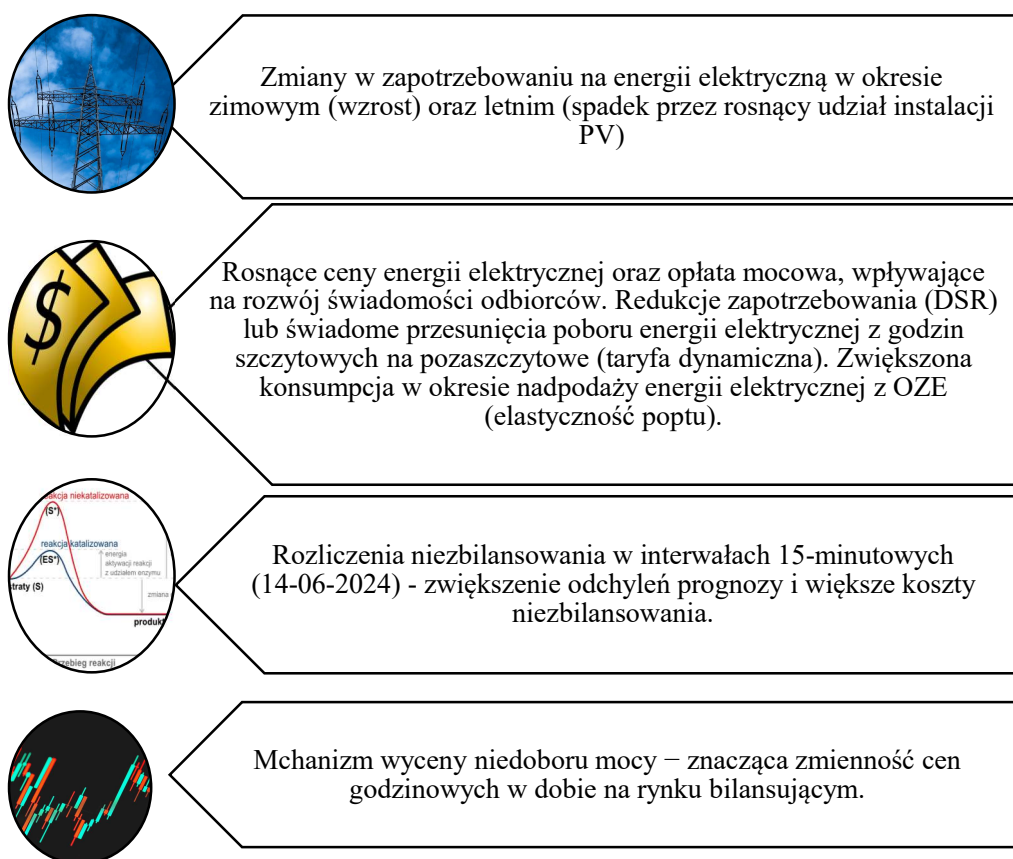
W przypadku rynku długoterminowego [84, 85] również można wskazać pozytywne aspekty wykorzystania prognoz:

- Dzięki dokładniejszym prognozom generacji PV i zapotrzebowania, traderzy mogą lepiej bilansować swoje pozycje na rynku terminowym, np. zwiększając pozycje na produktach peak w okresach wysokiego zapotrzebowania i niskiej generacji PV.
- Prognozy mogą pomóc w identyfikacji potencjalnych, arbitrażowych sytuacji na rynku, np. różnic cenowych między produktami base a peak, które mogą być wykorzystywane do osiągnięcia zysku.
- Prognozy pozwalają na efektywniejsze zabezpieczenie portfela przed wahaniami cen energii, przez wykorzystanie instrumentów pochodnych.
- Dzięki dokładniejszym prognozom można lepiej ocenić płynność rynku i uniknąć sytuacji, w których trudno jest szybko zamknąć pozycję.
- Prognozy długoterminowe mogą być wykorzystane do opracowania strategii handlowych opartych na sezonowych wahaniami zapotrzebowania i generacji PV.

7 PODSUMOWANIE I WNIOSKI KOŃCOWE

Przeprowadzone badania potwierdziły złożony, wieloparametryczny charakter procesu prognozowania zapotrzebowania na energię elektryczną i gaz na rynku dnia następnego. Analiza literaturowa obejmowała metody prognozowania zarówno klasyczne, jak i z elementami AI, w tym metody statystyczne, zaawansowane techniki uczenia maszynowego, sieci neuronowe i drzewa decyzyjne. Wykonane badania pozwoliły na wypracowanie nowego podejścia, poprawiającego dokładność prognoz oraz minimalizujących straty, wynikające z błędów przewidywań.

Ryzyko, jakie zostało zidentyfikowane przedstawiono na poniższym schemacie (rys. 7.1).



Rys. 7.1. Zidentyfikowane, w ramach prac badawczych, ryzyko i wyzwania stojące przed spółką obrotu

Fig. 7.1. Risk and challenges faced by the trading company identified during the research work

Dokładne przewidywanie poziomu produkcji i zużycia energii elektrycznej oraz gazu ziemnego ma kluczowe znaczenie w kontekście ograniczenia ryzyka niezbilansowania pozycji handlowej spółek obrotu. Zapotrzebowanie na energię elektryczną, po stronie dystrybucyjnej, jest funkcją wielu czynników, w tym: generacji fotowoltaicznej (w przypadku zapotrzebowania netto), temperatury powietrza, wahań sezonowych oraz aktywności społecznej (dni robocze, weekendy, święta i okresy okołoswiąteczne) i innych. Aby minimalizować ryzyko wyszczególnione powyżej, spółki obrotu powinny wykorzystywać najlepsze możliwe dane i modele do prognozowania zapotrzebowania i generacji. Algorytmy prognozujące zużycie energii elektrycznej muszą spełniać wiele

wymagań. Muszą być wystarczająco proste, aby można je było łatwo wdrożyć i utrzymać. Muszą być również odporne na zmiany danych oraz pojawienie się nowych trendów w danych. Ponadto powinny uwzględniać różnorodność czynników, które wpływają na zużycie energii. Niestety pojawiają się ograniczenia i dodatkowe zakłócenia w procesie prognozowania. Są to między innymi, wskazane poniżej, zidentyfikowane problemy:

- dostarczanie danych o zapotrzebowaniu z opóźnieniem 1-5-dniowym,
- początkowo udostępniane dane niskiej jakości powodują znaczne odchylenia modeli automatycznych, niemających algorytmu kontroli poprawności danych,
- możliwość korygowania danych historycznych przez OSD i OSP nawet do 15 miesięcy wstecz,
- migracja klientów pomiędzy spółkami obrotu – liczba klientów może się zmieniać każdego dnia, zwykle jednak zmiana sprzedawcy następuje z początkiem pierwszego dnia miesiąca. Największa migracja klientów następuje z pierwszym dniem kalendarzowym roku. Ma to związek z zawieraniem kontraktów na okres pełnego roku kalendarzowego,
- wdrażanie i oferowanie klientom nowych produktów (taryfa dynamiczna, zwiększanie zapotrzebowania, DSR), co powoduje zwiększenie elastyczności systemu energetycznego, ale również zwiększa zmienność i niepewność prognoz.

W badaniach uwzględniono istotne czynniki, wpływające na zmienność zapotrzebowania, takie jak zmienne meteorologiczne oraz dynamicznie rosnący udział odnawialnych źródeł energii, szczególnie mikroinstalacji fotowoltaicznych. Wykonano dekompozycję danych o zużyciu klientów netto, na zapotrzebowanie brutto oraz generację z PV. Przeprowadzono również badanie korelacji tych składowych ze zmiennymi objaśniającymi, co umożliwiło wybór modeli prognostycznych i prognoz meteorologicznych o większej dokładności. Wybrane metody prognozowania wykazały wysoką skuteczność w dopasowaniu, osiągając współczynnik R^2 na poziomie od 0,85 do 0,86. Biorąc pod uwagę, że instalacje PV są rozproszone, a prognozy temperatury i natężenia promieniowania słonecznego są punktowe oraz to, że dane zostały „odtworzone” z profilu brutto, wynik można uznać za dobry. Oddzielenie składowej zapotrzebowania brutto, umożliwiło wybór najlepszego modelu. We wszystkich badanych obszarach najlepiej sprawdzała się metoda hybrydowa, łącząca prognozy z różnych modeli. Osiągnięte wyniki R^2 na poziomie od 0,91 do 0,94 oraz odchylenia poniżej 5% (poza obszarem Wrocław) są również na dobrym poziomie. Wybór metod prognozowania składowych pozwolił na optymalne przygotowanie prognozy zapotrzebowania netto i porównania jej z metodą referencyjną. W każdym z badanych obszarów nastąpiła poprawa wyników od 0,5 pp. do 2 pp., co przeniosło się również na poprawę kosztu niezbilansowania od 0,5 do prawie 3 mln zł. Przeprowadzone badania wykazały poprawę dokładności prognoz zapotrzebowania netto, dzięki wykorzystaniu zarówno zapotrzebowania brutto, jak i składowej „generacja PV”. Metoda ta jednak wymaga większej liczby parametrów, a także trenowania i aktualizacji wielu modeli, co prowadzi do wydłużenia czasu potrzebnego na przeliczenie prognoz.

Jednym z kluczowych wyzwań badawczych był dobór metody agregacji przy dużej zmienności danych wejściowych, co odgrywa istotną rolę w poprawie jakości prognoz. Przeanalizowano również poziom trafności prognoz meteorologicznych, które mają bezpośredni wpływ na precyzję przewidywania zapotrzebowania, szczególnie w kontekście produkcji energii elektrycznej z fotowoltaiki. Przeprowadzono ocenę ekonomicznych konsekwencji błędów prognozowania, które mogą prowadzić do dodatkowych kosztów operacyjnych, a nawet do destabilizacji systemu energetycznego. Badania wykazały, że integracja zmiennych meteorologicznych, takich jak nasłonecznienie i temperatura, oraz wykorzystanie łączenia modeli predykcyjnych pozwala na znaczną poprawę jakości prognoz. Wskazano również kierunki dalszych badań, w tym wykorzystanie głębokich sieci neuronowych i hybrydowych metod prognozowania, które mogą jeszcze bardziej zoptymalizować zarządzanie energią w kontekście zmienności generacji ze źródeł odnawialnych.

Opracowane podejście, w opinii Autora, wnosi element oryginalnego rozwiązania, wprowadzającego optymalizację doboru zmiennych objaśniających oraz zastosowanie nowych metod agregacji danych. Znajduje to praktyczne zastosowanie zarówno na poziomie spółek obrotu, operatorów systemów dystrybucyjnych, jak i podmiotów odpowiedzialnych za bilansowanie. Wnioski z pracy mogą być podstawą do dalszego rozwoju i doskonalenia metod prognozowania, w tym wdrożenia bardziej zaawansowanych technik, takich jak głębokie sieci neuronowe czy metody hybrydowe. Umożliwi to zwiększenie precyzji prognoz w kontekście rosnącej zmienności generacji OZE.

Projekt prognozowania został pomyślnie wdrożony w spółce obrotu. Prognozy realizowane są równolegle według dotychczasowej metody oraz metody wypracowanej w ramach doktoratu wdrożeniowego. Wyniki pokazały, że metoda zaproponowana w projekcie badawczym osiąga postęp w stosunku do innych metod, wykonywanych w podobnych warunkach. Wyniki testów wdrożeniowych wskazują na skuteczność zastosowanych metod, biorąc jednak pod uwagę ciągłe i dynamiczne zmiany na rynku energii, rekomendowane są dalsze badania nad doskonaleniem modeli prognozowania. Modele prognostyczne są wykorzystywane jako wsparcie dla specjalistów do spraw prognozowania, w celu wygenerowania jak najdokładniejszej predykcji wolumenu energii elektrycznej i gazu ziemnego, która będzie podstawą do operacji przeprowadzanych na rynku energii. Dokładniejszy model predykcyjny pozwoli nie tylko na stworzenie dokładniejszej prognozy pozycji handlowej spółki obrotu na rynku dnia następnego, ale może zostać wykorzystany do precyzyjniejszego zarządzania energią na rynku dnia bieżącego. Uwzględniając powyższe, można stwierdzić, że zarówno ogólny, jak i szczegółowe cele pracy zostały osiągnięte. Zaproponowana metoda poprawia wyniki prognoz zapotrzebowania na energię elektryczną, może też być stosowana do prognoz na rynku gazowym, w przypadku pojawienia się podobnego zjawiska.

8 KIERUNKI DALSZYCH BADAŃ

Dalsze kierunki badań powinny koncentrować się na kilku kluczowych obszarach, mających na celu poprawę dokładności prognozowania oraz optymalizację kosztów bilansowania w kontekście mikroinstalacji OZE. W szczególności dotyczy to poniższych aspektów:

1. **Rosnących kosztów bilansowania** – koszty bilansowania rosną ze względu na nieprzewidywalność generacji źródeł OZE. Uzasadnione wydaje się przeniesienie tych kosztów bezpośrednio na odbiorców mających mikroinstalacje, zamiast obciążania nimi wszystkich odbiorców energii elektrycznej. Jednak to właśnie mikroinstalacje obniżają ceny energii na giełdzie w okresach, kiedy prosumenci nie są w stanie skonsumować energii, którą produkują. Wtedy z taniej energii korzystają pozostali odbiorcy. Ceny za niezbilansowanie energii elektrycznej stanowią najwyższą zachętę do zawierania umów z wyprzedzeniem i wywiązywania się ze swoich zobowiązań (minimalizacji odchyleń). W miarę zbliżania się terminu dostawy uczestnicy rynku energii muszą ocenić, czy wymienić pozycję czy rozliczyć ją na rynku bilansującym po nieznanym jeszcze cenie niezbilansowania. Prognozowanie ceny niezbilansowania (i związanych z nią wolumenów) jest zatem koniecznością na rynkach krótkoterminowych. Jednakże tematowi temu poświęcono zaskakująco mało uwagi w literaturze akademickiej, mimo wyraźnej potrzeby ze strony praktyków. Co więcej, pojawienie się handlu algorytmicznego [76, 77] wymaga zautomatyzowanego prognozowania i podejmowania decyzji. Uczestnicy rynku, którzy najlepiej potrafią wydobywać informacje predykcyjne z dostępnych danych, zyskują przewagę konkurencyjną [11].
2. **Dokładności danych rzeczywistych** – dane historyczne dotyczące zapotrzebowania na energię dostarczane są z opóźnieniem, wynoszącym od 1 do 5 dni. Zazwyczaj dopiero po 4 dniach dostępne są wystarczająco dokładne dane, aby można było je efektywnie wykorzystać w prognozowaniu. Warto również zauważyć, że dane te mogą podlegać korektom, a ostateczne wartości są zatwierdzone jako ostateczne dopiero po upływie 15 miesięcy. Do zidentyfikowania szybko zmieniających się trendów jest to zbyt długi okres i należy go skrócić lub pozyskać dane referencyjne (np. próbki danych) z innych źródeł.
3. **Prognozowania generacji mikroinstalacji PV** – separacja składowej odpowiadającej za generację mikroinstalacji fotowoltaicznych (za licznikiem) z danych o zapotrzebowaniu netto umożliwia lepszy dobór algorytmów prognostycznych oraz zmiennych objaśniających.
4. **Analizy dokładności modeli meteorologicznych** – dokładność prognoz generacji fotowoltaicznej oraz energii wprowadzonej do sieci jest ściśle uzależniona od precyzji prognoz dotyczących natężenia promieniowania słonecznego. Poprawa dokładności prognoz zapotrzebowania na energię elektryczną może zostać osiągnięta przez łączenie prognoz meteorologicznych od różnych dostawców, wykorzystywanie prognoz meteorologicznych dla

lokalizacji o największym zagęszczeniu instalacji fotowoltaicznych oraz skracanie horyzontu prognozy. Im krótszy horyzont czasowy, tym dokładniejsza prognoza meteorologiczna, co bezpośrednio przekłada się na jakość modeli prognostycznych. To w konsekwencji, w przyszłości może spowodować przeniesienie części handlu z rynku dnia następnego na rynek dnia bieżącego.

5. **Dane o generacji mikroinstalacji PV** – wykorzystanie danych rzeczywistych z jak największej liczby instalacji PV rozmieszczonych na obszarze działalności spółki obrotu umożliwiłoby odwzorowanie rzeczywistej generacji źródeł PV. Liczniki dystrybucyjne nie umożliwiają pomiaru generacji, dlatego spółki obrotu muszą pozyskać dane w inny sposób. Wartym rozważenia jest pomysł wykorzystania liczników instalowanych przez odbiorców w ramach wewnętrznego opomiarowania instalacji PV.

Dalsze prace nad tymi zagadnieniami mogą przyczynić się do zmniejszenia ryzyka niezbilansowania oraz zoptymalizowania kosztów bilansowania dla spółek obrotu, co jest szczególnie ważne w obliczu rosnącej integracji odnawialnych źródeł energii z systemem energetycznym.

BIBLIOGRAFIA

1. Wołoszyn J., Metody doboru zmiennych do modelu, Dydaktyka Informatyki, 2021.
2. Machał P., Remiorz L., Bukowiec D., Analiza wstępna wybranych aspektów krótkoterminowych prognoz zapotrzebowania na energię elektryczną w kontekście dynamicznego rozwoju źródeł odnawialnych, Rynek Energii, vol. 5, s. 11-15, 2022.
3. Wójcicki R., Autokonsumpcja energii elektrycznej w prosumenckiej osłonie kontrolnej, *Rynek Energii*, 2020.
4. Matuszczyk P., Popławski T., Flaszka J., Wpływ natężenia promieniowania słonecznego i temperatury modułu na wybrane parametry i moc znamionową paneli fotowoltaicznych, *Przegląd Elektrotechniczny*, 12, s.159-162, 2015.
5. XI kongres PORT PC. (2024). https://portpc.pl/pdf/11Kongres/1.2_Pawel_Lachman.pdf
6. NFOŚiGW. (2024). Źródła ciepła. <https://czystepowietrze.gov.pl/efekty-programu/zrodla-ciepla>
7. TGE. (2024, 04). Pobrano z lokalizacji www.tge.pl
8. Malko J., Wybrane zagadnienia prognozowania w elektroenergetyce: Prognozowanie zapotrzebowania energii i mocy elektrycznej. Oficyna Wydaw. Politech. Wrocławskiej, Wrocław 1995.
9. P. Li, K. Zhou, X. Lu, S. Yang, A hybrid deep learning model for short-term PV power forecasting, *Applied Energy*, 1, 2, 2020.
10. Zippenfenig P., Open-Meteo.com Weather API [Oprogramowanie komputerowe]. Zenodo., 2023, <https://doi.org/10.5281/ZENODO.7970649>.
11. Jethro, Browell., Ciaran, Gilbert. Przewidywanie cen i wolumenów niezbilansowania energii elektrycznej: możliwości i szanse. *Energie*, 15(10), 2022, s. 3645-3645. DOI: 10.3390/en15103645.
12. Ceny. (2024). <https://energy.instrat.pl/ceny/energia-rdn-godzinowe/>.
13. Ding Han, Hongkun Bai, Yuanyuan Wang, Feifei Bu, Jian Zhang, Day-ahead aggregated load forecasting based on household smart meter data, *Energy Reports*, Vol. 9, Supplement 8, 2023, p. 149-158, ISSN 2352-4847, <https://doi.org/10.1016/j.egy.2023.04.317>.
14. Longbo, Huang., Jean, Walrand., Kannan, Ramchandran. Optimal demand response with energy storage management. 2012. DOI: 10.1109/SMARTGRIDCOMM.2012.6485960
15. Lincoln, Mamoru, Fujita. (2009). 2. Method and system for managing a load demand on an electrical grid.
16. Fallah S.N., Ravinesh C., Deo., Mohammad, Shojafar., Mauro, Conti., Shahaboddin, Shamsirband. Computational intelligence approaches for energy load forecasting in smart energy management grids: state of the art, future challenges and research directions and *Research Directions*.3, 2018.
17. Antimo, Barbato., Antonio, Capone., M., Rodolfi., D., Tagliaferri. Forecasting the usage of household appliances through power meter sensors for demand management in the smart grid.4, 2011. DOI: 10.1109/SMARTGRIDCOMM.2011.6102356.

18. Donal, Finn., Fabiano, Pallonetto., Changhong, Jin., Eleni, Mangina. Forecast electricity demand in commercial building with machine learning models to enable demand response programs. 6, 2022. DOI: 10.1016/J.EGYAI.2021.100121.
19. Mohammad, Aminul, Islam., Hang, Seng, Che., Md., Hasanuzzaman., Nasrudin, Abd, Rahim. Energy demand forecasting. 8, 2020. DOI: 10.1016/B978-0-12-814645-3.00005-5.
20. Sri, Krishna, A Review on Electrical Load Forecasting in Energy Management. 10, 2015.
21. Raza M.Q., Nadarajah M., Ekanayake C., On recent advances in PV output power forecast models and their comparison". Renewable and Sustainable Energy Reviews, 81, 2019, p. 2812-2827.
22. Kim Y., Cho H., Electricity demand forecasting based on decision trees and support vector regression. Applied Energy, 262, 2020, 114499.
23. Chen H., Xu Y., Zhu X., A review on day-ahead electricity price forecasting using machine learning algorithms. Energy Conversion and Management, 221, 2020, 113165.
24. Markovics D., Mayer M.J., Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction, Renewable and Sustainable Energy Reviews, Vol. 161, 2022, 112364, ISSN 1364-0321, <https://doi.org/10.1016/j.rser.2022.112364>.
25. Bessec M., Fouquau J., The non-linear link between electricity consumption and temperature in Europe: A threshold panel approach. *Energy Economics*, 30(5), 2008, p. 2705-2721.
26. Pardo A., Meneu V., Valor E., Temperature and seasonality influences on Spanish electricity load. *Energy Economics*, 24(1), 2002, p. 55-70.
27. Sivill L., Peltola-Ojala M., Kosonen R., Impact of climate change on electricity demand in the built environment: A case study in Northern Europe. *Sustainable Cities and Society*, 55, 2020, p. 102046.
28. Fan S., Hyndman R.J., Short-term load forecasting based on a semi-parametric additive model. *IEEE Transactions on Power Systems*, 27(1), 2012, p. 134-141.
29. Hong T., Fan S., Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting*, 32(3), 2016, p. 914-938.
30. CAISO (California Independent System Operator). What the Duck Curve Tells Us About Managing a Green Grid. 2016.
31. Denholm P., Margolis R.M., Evaluating the limits of solar photovoltaics (PV) in traditional electric power systems. *Energy Policy*, 35(5), 2007, p. 2852-2861.
32. Martín-Martínez F., Sánchez-Miralles Á., Rivier M., A literature review of Microgrids: A functional layer-based classification. *Renewable and Sustainable Energy Reviews*, 62, 2015, p. 113-119.
33. Prost J., Schickele J., Demailly D., Vaillancourt K., *Energy self-consumption and self-sufficiency of households: Analysis based on empirical data in Europe*, 2020.
34. Luthander R., Widén J., Nilsson D., Palm J., *Photovoltaic self-consumption in buildings: A review*, Applied Energy, 2015.

35. Hoppmann J., Volland J., Schmidt T.S., Hoffmann V.H., *The economic viability of battery storage for residential solar photovoltaic systems – A review and a simulation model*, *Renewable and Sustainable Energy Reviews*, 2014.
36. Zachariás P., Michalakelis C., Psarras J., *Self-consumption and Net-Metering schemes: A review of the existing literature*, *Renewable and Sustainable Energy Reviews*, 2020.
37. Machał P., Remiorz L., Bukowiec D., Comparative analysis of the results of forecasts of electricity supplied to the grid by prosumers. [W:] *Międzynarodowa XIV Konferencja Kotłowa ICBT. Poland 2022. Aktualne problemy budowy i eksploatacji kotłów. Technologie transformacji energetycznej. Problemy eksploatacji elektrowni, elektrociepłowni i ciepłowni*, t. 52, s. 181-182, Szczyrk 25-28 października 2022.
38. Zarate E.J., Palumbo M., Motta A.L.T., Grados J., Forecasting photovoltaic power using bagging feed-forward neural network. 2020. DOI: 10.24247/IJMPERDJUN 20201188.
39. Stephen K., Pinto M., Mansfield R., Rubin D.B., Hirshberg J.C., Predictive model development, 2004.
40. Bruce, Thompson, Stepwise Regression and Stepwise Discriminant Analysis Need Not Apply here: A Guidelines Editorial.: Educational and Psychological Measurement, 1, 1995. DOI: 10.1177/0013164495055004001.
41. Acharya S.K., Wi Y.-M., Lee J., Day-Ahead Forecasting for Small-Scale Photovoltaic Power Based on Similar Day Detection with Selective Weather Variables. *Electronics*. 9(7),1117, 2020, <https://doi.org/10.3390/electronics9071117>
42. Hastie T., Tibshirani R., Friedman J., *The Elements of Statistical Learning*. Springer New York Inc., New York, USA 2001.
43. Svoboda R., Basterrech S., Kozal J., Platos J., Wozniak M., A Natural Gas Consumption Forecasting System for Continual Learning Scenarios based on Hoeffding Trees with Change Point Detection Mechanism. arXiv.org, 2023. DOI: 10.48550/arxiv.2309.03720.
44. Jia, Ding., Yuxuan, Zhao., Junyang, Jin. (2023). Forecasting natural gas consumption with multiple seasonal patterns. *Applied Energy*. DOI: 10.1016/j.apenergy. 2023.120911
45. Ayse, Ozmen, Multi-objective regression modeling for natural gas prediction with ridge regression and CMARS, 2022. DOI: 10.11121/ijocta.2022.1084.
46. Xueqing, Ni., Dongsheng, Yang., Jia, Qin., Xin, Wang, A multivariate natural gas load forecasting method based on residual recurrent neural network. *Electronics Letters*, 2023. DOI: 10.1049/ell2.12927.
47. Merkel G.D., Povinelli R.J., Brown R.H., Short-Term Load Forecasting of Natural Gas with Deep Neural Network Regression. *Energies* 2018, 11, 2008.
48. McKelvey R.D., Zavoina W., A statistical model for the analysis of ordinal level dependent variables. *J. Math. Sociol.* 2010, 4, p. 103-120.
49. Panek W., Włodek T., Natural Gas Consumption Forecasting Based on the Variability of External Meteorological Factors Using Machine Learning Algorithms. *Energies*. 15(1):348, 2022, <https://doi.org/10.3390/en15010348>.

50. Mohammad M., Abdullah M., Forecasting Natural Gas Demand Using Artificial Neural Networks and Regression Techniques. *Journal of Petroleum Science and Engineering*, 183, 2020, 106485.
51. Wang Y., Chen Y., Short-term natural gas demand forecasting based on improved support vector regression. *Energy Reports*, 5, 2019, p. 438-447.
52. Omidvar A., Mohammadi A., Forecasting natural gas consumption using wavelet transform and artificial neural network." *Applied Energy*, 261, 2020, 114339.
53. Kim Y., Yoo S., Natural Gas Demand Forecasting Using Lagged Variables and Neural Networks. *Energy*, 40(1), 2012, p. 236-241.
54. Clements M.P., Hendry D.F., Forecasting Energy Demand: A Study of Lagged Variables in Time Series Models. *Energy Economics*, 21(3), 1999, p. 185-209.
55. Kancelaria Główna. Słownik rynku energii (2024.07). <https://ochronaklimatu.com/slownik-rynku-energii/469-podmiot-odpowiedzialny-za-bilansowanie-pob>
56. Gueymard C.A., Clear-sky irradiance predictions for solar resource mapping and large-scale applications: Improved validation methodology and detailed performance analysis of 18 broadband radiative models. *Solar Energy*, 73(5), 2003, p. 379-391.
57. Boland J., Huang J., Ridley B., Decomposing global solar radiation into its direct and diffuse components. *Renewable Energy*, 33(4), 2008, p. 720-727.
58. Perez R., Seals R., Michalsky J., All-weather model for sky luminance distribution—Preliminary configuration and validation. *Solar Energy*, 50(3), 1993, p. 235-245.
59. Popovska E., Georgieva-Tsaneva G., ARIMA Model for Day-Ahead Electricity Market Price Forecasting. *Innovative STEM Education*, 2022. DOI: 10.55630/stem.2022.0418.
60. Hussein H., Abdellatif H., Hussein A., Ali T., Al-Awami M., Abido A., Real-time Electricity Market Price Prediction using Improved ARIMA Model, 2023. DOI: 10.1109/eeeic/icpseurope57605.2023.10194648.
61. Xiaodong Li., Gang Liu., Shenghuo Zhu. Market Electricity Price Forecasting Model Based on ARIMA-LSTM. *Advances in transdisciplinary engineering*, 2024. DOI: 10.3233/atde231279.
62. Farjana Mahia., Arpita, Rani, Dey., Abdul, Masud., Mohammad, Sultan, Mahmud. Forecasting Electricity Consumption using ARIMA Model., 2019. DOI: 10.1109/STI47673.2019.9068076.
63. Francesco, Lisi., Ismail, Shah. 2. Forecasting next-day electricity demand and prices based on functional models. *Energy Systems*, 2020. DOI: 10.1007/S12667-019-00356-W.
64. Amral N., Ozveren, Cuneyt, King, David. Short term load forecasting using Multiple Linear Regression. *Proceedings of the Universities Power Engineering Conference*. 2007, 1192-1198. 10.1109/UPEC.2007.4469121.
65. Prakhar, Chhavi Bajpai, Comparative analysis of simple moving average and cumulative moving average in financial time series forecasting. *International journal of innovative research in computer science & technology*, 2024. DOI: 10.55524/csistw.2024.12.1.17.

66. Hyndman R.J., Athanasopoulos G., *Forecasting: Principles and Practice*. (2nd ed.) OTexts, 2018, <https://otexts.org/fpp2/>.
67. Chapagain K., Gurung S., Kulthanavith P., Kittipiyakul S., Short-Term Electricity Demand Forecasting Using Deep Neural Networks: An Analysis for Thai Data. *Applied System Innovation*, 2023, <https://doi.org/10.3390/asi6060100>.
68. Kiartzis S.J., Bakirtzis A.G., Petridis V., Short-term load forecasting using neural networks. *Electric Power Systems Research*. Vol. 33. Issue 1, 1995, p. 1-6. ISSN 0378-7796, [https://doi.org/10.1016/0378-7796\(95\)00920-D](https://doi.org/10.1016/0378-7796(95)00920-D).
69. Pavićević M., Popović T., Forecasting Day-Ahead Electricity Metrics with Artificial Neural Networks. *Sensors*. 22(3), 2022, 1051. <https://doi.org/10.3390/s22031051>.
70. Hsiao-Tien Pao, Forecasting electricity market pricing using artificial neural networks. *Energy Conversion and Management*. Vol. 48. Issue 3, 2007, p. 907-912. ISSN 0196-8904. <https://doi.org/10.1016/j.enconman.2006.08.016>.
71. Kazem H.A., Yousif J.H., Comparison of prediction methods of photovoltaic power system production using a measured dataset. *Energy conversion and management*, 148, 2017, 1070-1081.
72. Sangrody H., Zhou N., Zhang Z., Similarity-based models for day-ahead solar PV generation forecasting. *IEEE Access*, 8, 2020, 104469-104478.
73. Salamanis A.I., Xanthopoulou G., Bezas N., Timplalexis C., Bintoudi A.D., Zyglakis L., Tzovaras D., Benchmark comparison of analytical, data-based and hybrid models for multi-step short-term photovoltaic power generation forecasting. *Energies*, 13(22), 2020, 5978.
74. Mayer M.J., Gróf G., Extensive comparison of physical models for photovoltaic power forecasting. *Applied Energy*, 283, 2021, 116239.
75. Dolara A., Leva S., Manzolini G., Comparison of different physical models for PV power output prediction. *Solar energy*, 119, 2015, p. 83-99.
76. Wang W., Yu N., A machine learning framework for algorithmic trading with virtual bids in electricity markets. In *2019 IEEE power & energy society general meeting (PESGM)*, 2019, August, pp. 1-5. IEEE.
77. Pradhan A., Subramanian E., Bhat S., Paruchuri P., Gujar S., Rise of Algorithmic Trading in Today's Changing Electricity Market, [in:] *ISUW 2020: Proceedings of the 6th International Conference and Exhibition on Smart Grids and Smart Cities*, Springer Nature Singapore, Singapore 2022, May, p. 49-60.
78. Chen T., Guestrin C., Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, August, p. 785-794.
79. Tanidir Ö., Tör O.B., Accuracy of ANN based day-ahead load forecasting in Turkish power system: Degrading and improving factors. *Neural Network World*, 25(4), 2015, p. 443.
80. Abbasi R.A., Javaid N., Ghuman M.N.J., Khan Z.A., Ur Rehman S., Amanullah, Short term load forecasting using XGBoost, [in:] *Web, Artificial Intelligence and Network Applications: Proceedings of the Workshops of the 33rd International Conference on Advanced Information Networking and Applications (WAINA-2019)*. Springer International Publishing, 33, 2019, p. 1120-1131.

81. Maciejowska K., Nitka W., Weron T., Day-Ahead vs. Intraday – Forecasting the Price Spread to Maximize Economic Benefits. *Energies*, 9, 2019. DOI: 10.3390/EN12040631.
82. Nidhisha, Mahilong., Venkatesh, Sarangan., Yogesh, Kumar, Bichpuriya., Ashutosh, Prajapati., Narayanan, Rajagopal. Trading Strategy for Renewable Energy Sources in Day-Ahead and Continuous Intraday Market., 2, 2022. DOI: 10.1109/ISGTAsia54193.2022.10003610.
83. Despoina, Kothona., Konstantin, D., Spyropoulos., Christos, Valelis., Charilaos, Koutsis., K., Ch., Chatzisavvas., Georgios, C., Christoforidis. Deep learning forecasting tool facilitating the participation of photovoltaic systems into day-ahead and intra-day electricity markets. *Sustainable Energy, Grids and Networks*, 6, 2023. DOI: 10.1016/j.segan.2023.101149.
84. Bhagwat P.C., Marcheselli A., Richstein J.C., Chappin E.J., De Vries L.J., An analysis of a forward capacity market with long-term contracts. *Energy policy*, 111, 2017, p. 255-267.
85. Simshauser P., Merchant renewables and the valuation of peaking plant in energy-only markets. *Energy Economics*, 91, 2020, 104888.
86. Ismael, Ahrazem, Dfuf., José, Manuel, Mira, McWilliams., María, Camino, González, Fernández. 1. Multi-Output Conditional Inference Trees Applied to the Electricity Market: Variable Importance Analysis. *Energies*, 2019. DOI: 10.3390/EN12061097.
87. Lingyun He., Zhihua Ding., Fang Yin., Meng Wu., The impact of relative energy prices on industrial energy consumption in China: a consideration of inflation costs. *SpringerPlus*, 2, 2016. DOI: 10.1186/S40064-016-2661-Z.
88. Xavier Labandeira., Xavier Labandeira., José M., Labeaga., Xiral, López-Otero. A meta-analysis on the price elasticity of energy demand. *Research Papers in Economics*, 4, 2015.
89. Milad, Afzalan., Farrokh, Jazizadeh. Quantification of Demand-Supply Balancing Capacity among Prosumers and Consumers: Community Self-Sufficiency Assessment for Energy Trading. *Energies*, 1, 2021. DOI: 10.3390/EN14144318.
90. Jiashu, Wang., Ying, Wang., Zetian, Zhong., Gang, Ma., Research on Prosumer Combining Household Electricity, Electric Vehicle Home Charging and Photovoltaic Power Generation. *American Journal of Electrical and Electronic Engineering*, 2, 2019. DOI: 10.12691/AJEEE-7-1-4.
91. Shariq, Riaz., Hesamoddin, Marzooghi., Gregor, Verbic., Archie, C., Chapman., David, J., Hill., Generic Demand Model Considering the Impact of Prosumers for Future Grid Scenario Analysis. *IEEE Transactions on Smart Grid*, 3, 2019. DOI:10.1109/TSG.2017.2752712.
92. Agnès Lomascolo-Pujadó., Herminio Martinez-Garcia, Contribution to Collaborative Electricity Microgrid Management Strategies of Domestic Prosumers. *Renewable energy & power quality journal*, 2022. DOI: 10.24084/repqj20.387.
93. Sebastian., Schreck., Ines., Prieur, de, La, Comble., Sebastian., Thiem., Stefan., Niessen, A Methodological Framework to support Load Forecast Error Assessment in Local Energy Markets. *IEEE Transactions on Smart Grid*, 2020. DOI: 10.1109/TSG.2020.2971339.

94. Axel Gautier, Julien Jacqmin, Jean-Christophe Poudou, The prosumers and the grid. *Journal of Regulatory Economics*, 2018. DOI: 10.1007/S11149-018-9350-5
95. Energy Prosumer for Local Energy Marketplace, 2023. DOI: 10.1109/icit58465.2023.10143096.
96. A Machine Learning Approach for Prosumer Management in Intraday Electricity Markets, 2022. DOI: 10.48550/arxiv.2203.06053.
97. Machał P., Remiorz L., Bukowiec D., Autokonsumpcja prosumenów w prognozowaniu zapotrzebowania na energię elektryczną, *Międzynarodowa Konferencja Naukowa „Aktualne problemy w elektroenergetyce. APE*, 23, 2023, p. 197-207.
98. Bonilla-Campos I., Sorbet F.J., Astrain D., Radical change in the Spanish grid: Renewable energy generation profile and electric energy excess, *Sustainable Energy, Grids and Networks*, 2022.
99. Popczyk J., Transformacja energetyki. Paradygmatyczny triplet i mapa oraz trajektoria. *Śląskie Wiadomości Elektryczne*, cz. 1, 2, wrzesień 2018, cz. 3 - styczeń 2019.
100. Malska W., Analiza wybranych aspektów pracy KSE pod kątem zapotrzebowania mocy. *Przegląd Elektrotechniczny*, 7, 2024.
101. Mellit A., Pavan A. M., Lughi V., Deep learning neural networks for short-term photovoltaic power forecasting. *Renewable Energy*, 172, 2021, p. 276-288.
102. Connolly D., Lund H., Mathiesen B.V., Leahy M., A review of computer tools for analysing the integration of renewable energy into various energy systems. *Applied energy*, 87(4), 2010, p. 1059-1082.
103. Mathiesen B.V., Lund H., Karlsson K., 100% Renewable energy systems, climate mitigation and economic growth. *Applied energy*, 88(2), 2011, p. 488-501.
104. Krajačić G., Duić N., da Graça Carvalho M., How to achieve a 100% RES electricity supply for Portugal?. *Applied energy*, 88(2), 2011, p. 508-517.
105. Thiam D.R., Benders R.M., Moll H.C., Modeling the transition towards a sustainable energy production in developing nations. *Applied Energy*, 94, 2012, p. 98-108.
106. Bielecki S., Skoczkowski T., Sobczak L., Buchoski J., Maciąg Ł., Dukat P., Impact of the lockdown during the COVID-19 pandemic on electricity use by residential users. *Energies*, 14(4), 2021, p. 980.
107. Santiago I., Moreno-Munoz A., Quintero-Jiménez P., Garcia-Torres F., Gonzalez-Redondo M.J., Electricity demand during pandemic times: The case of the COVID-19 in Spain. *Energy policy*, 148, 2021, 111964.
108. Nowak B., Challenges of liberalization. The case of Polish electricity and gas sectors. *Yearbook of Antitrust and Regulatory Studies (YARS)*, 2(2), 2009, p. 141-168.
109. Neugebauer M., d'Obyrn J., Sołowiej P., Economic Analysis of Profitability of Using Energy Storage with Photovoltaic Installation in Conditions of Northeast Poland. *Energies*, 17(13), 2024, 3075.

110. Witkowska A., Krawczyk D.A., Rodero A., Analysis of the heat pump market in Europe with a special regard to France, Spain, Poland and Lithuania. *Environmental and Climate Technologies*, 25(1), 2021, p. 840-852.
111. Dongellini M., Naldi C., Morini G.L., Seasonal performance evaluation of electric air-to-water heat pump systems. *Applied Thermal Engineering*, 90, 2015, p. 1072-1081.
112. Anweiler S., Masiukiewicz M., Experimental based determination of SCOP coefficient for ground-water heat pump. In *E3S Web of Conferences*. Vol. 44, 2018, p. 00003). EDP Sciences.
113. Nadel S., Kallakuri C., Opportunities for Energy and Economic Savings by Replacing Electric Resistance Heat with Higher-Efficiency Heat Pumps. *American Council for an Energy-Efficient Economy (ACEEE)*, 2016.
114. Matuska T., Sourek B., Performance analysis of photovoltaic water heating system. *International Journal of Photoenergy*, 2017(1), 2017, 7540250.
115. Manoranjitham T., An Approach For Short Term Electricity Load Forecasting, 2023. DOI: 10.1109/ICNWC57852.2023.10127505.
116. Mbey C., Vinny, Junior, Foba, Kakeu., Alexandre, Teplaira, Boum., Felix, Ghislain, Yem, Souhe. Solar photovoltaic generation and electrical demand forecasting using multi-objective deep learning model for smart grid systems. *Cogent engineering*, 2024. DOI: 10.1080/23311916.2024.2340302.
117. Yidan, Hu., Yue, Chen., Fei, Wang., Han, Yang., Wudi, Bao., Junfang, Zhang. Study of a Aggregated Baseline Load Forecasting Method Based on Decoupling of Distributed PV-Containing Customers, 2023. DOI: 10.1109/ieses53571.2023.10253720.
118. Ghedamsi R., Settou N., Gouareh A., Khamouli A., Saifi N., Reციoui B., Dokkar B., Modeling and forecasting energy consumption for residential buildings in Algeria using bottom-up approach. *Energy and Buildings*, 121, 2016, p. 309-317.
119. Anagnostis A., Papageorgiou E., Bochtis D., Application of artificial neural networks for natural gas consumption forecasting. *Sustainability*, 12(16), 2020, p. 6409.
120. Mhlanga D., Artificial intelligence and machine learning for energy consumption and production in emerging markets: a review. *Energies*, 16(2), 2023, p. 745.
121. Ahmad T., Zhang D., Huang C., Zhang H., Dai N., Song Y., Chen H., Artificial intelligence in sustainable energy industry: Status Quo, challenges and opportunities. *Journal of Cleaner Production*, 289, 2021, 125834.
122. Cheng L., Yu T., A new generation of AI: A review and perspective on machine learning technologies applied to smart energy and electric power systems. *International Journal of Energy Research*, 43(6), 2019, p. 1928-1973.
123. Panapakidis I.P., Dagoumas A.S., Day-ahead natural gas demand forecasting based on the combination of wavelet transform and ANFIS/genetic algorithm/neural network model. *Energy*, 118, 2017, p. 231-245.
124. Entezari A., Aslani A., Zahedi R., Noorollahi Y., Artificial intelligence and machine learning in energy systems: A bibliographic perspective. *Energy Strategy Reviews*, 45, 2023, 101017.

125. Dongare A.D., Kharde R.R., Kachare A.D., Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 2012, p. 189-194.
126. Islam M., Chen G., Jin S., An overview of neural network. *American Journal of Neural Networks and Applications*, 5(1), 2019, p. 7-11.
127. Cox D.R., Prediction by exponentially weighted moving averages and related methods. *Journal of the Royal Statistical Society: Series B (Methodological)*, 23(2), 1961, 414-422.
128. Keles D., Scelle J., Paraschiv F., Fichtner W., Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks. *Applied energy*, 162, 2016, p. 218-230.
129. Mandal P., Senjyu T., Urasaki N., Funabashi T., Srivastava A.K., A novel approach to forecast electricity price for PJM using neural network and similar days method. *IEEE Transactions on Power Systems*, 22(4), 2007, 2058-2065.
130. Popczyk J., Cztery rynki elektroprosumeryzmu. *Biuletyn Rynki Elektroprosumeryzmu*, (1), 2020.
131. Tokarski S., Transformacja energetyczna-zapotrzebowanie na źródła energii pierwotnej w perspektywie 2040 r. Co się zmieni po wybuchu wojny na Ukrainie? *Nowa Energia*, 2022.
132. Popczyk J., Model interaktywnego rynku energii elektrycznej. www.klaster3x20.pl.
133. Wójcicki R., Informatyka w EP. www.klaster3x20.pl.
134. Mediavilla M.A., Dietrich F., Palm D., Review and analysis of artificial intelligence methods for demand forecasting in supply chain management. *Procedia CIRP*, 107, 2022, p. 1126-1131.
135. Arcese, Gabriella, Komal Aziz, Karol Badura, Puteri Nur Atiqah Bandira, Jakub Baran, Weronika Barańska, Hanna Barchańska i in., *Ochrona klimatu i środowiska, nowoczesna energetyka: wybrana problematyka*, (reed.) S. Werle, J. Ferdyn-Grygierek. Wydawnictwo Politechniki Śląskiej, Gliwice 2024, <https://doi.org/10.34918/88720>, s. 491-501.
136. Machał P., Remiorz L., Bukowiec D., Selected aspects of generating short-term electricity demand forecasts, taking into account renewable energy sources, *Energy Policy Studies* 1(12) 2023, S21-23, DOI: <https://doi.org/10.62316/IRCF4320>.

Spis rysunków

RYS. 1.1. DZIAŁALNOŚĆ HANDLOWA SPÓŁKI OBROTU.....	16
RYS. 2.1. HARMONOGRAM NOTOWAŃ NA RYNKU DNIA NASTĘPNEGO NA TGE [7].....	18
RYS. 2.2. WYNIKI NOTOWAŃ NA TGE PRZEDSTAWIAJĄCE GODZINOWE CENY ORAZ WOLUMENY ENERGI ELEKTRYCZNEJ [12]	19
RYS. 2.3. ZMIENNE OBJAŚNIAJĄCE UŻYWANE DO PROGNOZOWANIA ZAPOTRZEBOWANIA W METODACH POŚREDNIEJ ORAZ BEZPOŚREDNIEJ.....	22
RYS. 2.4. POGŁĄDOWY HARMONOGRAM PRZYGOTOWANIA PROGNOZ ZAPOTRZEBOWANIA	22
RYS. 2.5. KLASYFIKACJA MODELI PROGNOSTYCZNYCH [134].....	26
RYS. 2.6. PODOBIĘSTWA DNI POD KĄTEM ZAPOTRZEBOWANIA NA ENERGIĘ W OKRESIE PEŁNEGO ROKU KALENDARZOWEGO	32
RYS. 2.7. PODZIAŁ METOD PROGNOZOWANIA GENERACJI PV [9]	33
RYS. 2.8. GRAFICZNA PREZENTACJA SPRAWNOŚCI GENERACJI PV NA OBSZARZE, TZW. KRZYWA NASŁONECZNIENIA [37]	34
RYS. 3.1. PRZYROST MOCY ZAINSTALOWANEJ W MIKROINSTALACJACH W LATACH OD 2016 DO 2024, W PODZIALE NA OBSZARY	39
RYS. 3.2. WPŁYW GENERACJI FOTOWOLTAICZNEJ PROSUMENTÓW NA PROFIL ZAPOTRZEBOWANIA NETTO, NA WYBRANYM OBSZARZE	40
RYS. 3.3. SZACUNKOWA GENERACJA PV PROSUMENTÓW, WYZNACZONA Z RÓŻNICY PROFILU BRUTTO I NETTO W WYBRANYCH DNIACH 2022 ROKU NA WYBRANYM OBSZARZE.....	41
RYS. 3.4. TYPOWA KONFIGURACJA POMIAROWA MIKROINSTALACJI [3].....	42
RYS. 3.5. RÓWNANIE NA OBLICZENIE GHI, UŻYWAJĄC DNI I DHI [56]	43
RYS. 3.6. PRZYROST POMP CIEPŁA W POLSCE W LATACH OD 2010 DO 2022 [5]	44
RYS. 3.7. UDZIAŁ PROCENTOWY POSZCZEGÓLNYCH TECHNOLOGII WE WNIOSKACH PROGRAMU „CZYSTE POWIETRZE” [6]	45
RYS. 3.8. ZALEŻNOŚĆ POMIĘDZY DOBOWYM ZAPOTRZEBOWANIEM NA ENERGIĘ ELEKTRYCZNĄ A TEMPERATURĄ POWIETRZA NA WYBRANYM OBSZARZE	46
RYS. 3.9. DOBOWE ZAPOTRZEBOWANIE NA ENERGIĘ ELEKTRYCZNĄ NA WYBRANYM OBSZARZE..	48
RYS. 3.10. TYGODNIOWE ZAPOTRZEBOWANIE NA ENERGIĘ ELEKTRYCZNĄ NA WYBRANYM OBSZARZE	49
RYS. 3.11. ROCZNE ZAPOTRZEBOWANIE NA ENERGIĘ ELEKTRYCZNĄ NETTO NA WYBRANYM OBSZARZE	50

RYS. 3.12. ZAPOTRZEBOWANIE NA ENERGIĘ ELEKTRYCZNĄ NETTO NA WYBRANYM OBSZARZE W OKRESIE 9 LAT.....	51
RYS. 3.13. GEOGRAFICZNE ROZMIESZCZENIE MOCY ZAINSTALOWANEJ U PROSUMENTÓW W PODZIALE NA REJONY DYSTRYBUCYJNE	54
RYS. 3.14. SKŁADOWE PROGNOZY WCHODZĄCE W SUMĘ POZYCJI HANDLOWEJ SPÓŁKI OBROTU	55
RYS. 3.15. AGREGACJA KLIENTÓW W PODZIALE NA REJONY DYSTRYBUCYJNE	56
RYS. 3.16. ZAPOTRZEBOWANIE NA ENERGIĘ ELEKTRYCZNĄ, PRZEDSTAWIONE JAKO SZEREG CZASOWY, W PODZIALE NA SKŁADOWE ZAPOTRZEBOWANIA BEZ PROSUMENTÓW, ZAPOTRZEBOWANIE PROSUMENTÓW, ODDANIE ENERGII DO SIECI PRZEZ PROSUMENTÓW ...	58
RYS. 4.1. ALGORYTM DO ODTWORZENIA PROFILU BRUTTO I GENERACJI PV	62
RYS. 4.2. DANE O MOCY ZAINSTALOWANEJ MIKROINSTALACJI PV W LATACH 2016-2024, W PODZIALE NA DANE UCZĄCE I DANE DO ODTWORZENIA PROFILU BRUTTO.....	63
RYS. 4.3. PORÓWNANIE ŚREDNIEGO WSPÓŁCZYNNIKA ZMIENNOŚCI DLA ZAPOTRZEBOWANIA NETTO I BRUTTO W GODZINACH DOBY	64
RYS. 4.4. SCHEMAT STRUKTURY SIECI NEURONOWEJ DO GENERACJI PROFILU ZAPOTRZEBOWANIA BRUTTO.....	66
RYS. 4.5. PROCES UCZENIA SIECI NEURONOWEJ – OBSZAR 1	68
RYS. 4.6. PROCES UCZENIA SIECI NEURONOWEJ – OBSZAR 2	68
RYS. 4.7. PROCES UCZENIA SIECI NEURONOWEJ – OBSZAR 3	69
RYS. 4.8. WSKAŹNIKI ZWIĄZANE Z PROCESEM UCZENIA SIECI NEURONOWEJ – OBSZAR 1	70
RYS. 4.9. WSKAŹNIKI ZWIĄZANE Z PROCESEM UCZENIA SIECI NEURONOWEJ – OBSZAR 2.....	70
RYS. 4.10. WSKAŹNIKI ZWIĄZANE Z PROCESEM UCZENIA SIECI NEURONOWEJ – OBSZAR 3	71
RYS. 4.11. ROZKŁAD BŁĘDÓW HISTORYCZNEGO PROFILU BRUTTO – OBSZAR 1	72
RYS. 4.12. ROZKŁAD BŁĘDÓW HISTORYCZNEGO PROFILU BRUTTO – OBSZAR 2	72
RYS. 4.13. ROZKŁAD BŁĘDÓW HISTORYCZNEGO PROFILU BRUTTO – OBSZAR 3	73
RYS. 4.14. WYKRES DOPASOWANIA MODELU DO DANYCH – OBSZAR 1	74
RYS. 4.15. WYKRES DOPASOWANIA MODELU DO DANYCH – OBSZAR 2	75
RYS. 4.16. WYKRES DOPASOWANIA MODELU DO DANYCH – OBSZAR 3	76
RYS. 4.17. WYNIKI ALGORYTMU SZACOWANIA PROFILU BRUTTO I GENERACJI FOTOWOLTAICZNEJ	77
RYS. 4.18. OBSZAR 1 – PROFIL NETTO ORAZ PROFIL BRUTTO PO KOREKCIE.....	78
RYS. 4.19. OBSZAR 2 – PROFIL NETTO ORAZ PROFIL BRUTTO PO KOREKCIE.....	78
RYS. 4.20. OBSZAR 3 – PROFIL NETTO ORAZ PROFIL BRUTTO PO KOREKCIE.....	79

RYS. 4.21. OBSZAR 1 – GENERACJA PV I ODDANIE ENERGII DO SIECI	79
RYS. 4.22. OBSZAR 2 – GENERACJA PV I ODDANIE ENERGII DO SIECI	80
RYS. 4.23. OBSZAR 3 – GENERACJA PV I ODDANIE ENERGII DO SIECI	80
RYS. 4.24. OBSZAR 1 – GENERACJA PV I ENERGIA ODDANA DO SIECI	81
RYS. 4.25. OBSZAR 2 – GENERACJA PV I ENERGIA ODDANA DO SIECI	82
RYS. 4.26. OBSZAR 3 – GENERACJA PV I ENERGIA ODDANA DO SIECI	82
RYS. 4.27. PORÓWNANIE WSKAŹNIKÓW AUTOKONSUMPCJI	83
RYS. 5.1. ROZKŁAD BŁĘDÓW GENERACJI PV NA OBSZARZE 3	85
RYS. 5.2. BŁĘDY PROCENTOWE GENERACJI PV NA OBSZARZE 3 W PODZIALE NA GODZINY	86
RYS. 5.3. BŁĘDY PROCENTOWE GENERACJI PV NA OBSZARZE 3 W PODZIALE NA MIESIĄCE	87
RYS. 5.4. DWUTYGODNIOWA PROGNOZA I WYKONANIE RZECZYWISTE ORAZ ODCHYLENIA PROGNOZY NA OBSZARZE 3	87
RYS. 5.5. ROZKŁAD BŁĘDÓW GENERACJI PV NA OBSZARZE 2	88
RYS. 5.6. BŁĘDY PROCENTOWE GENERACJI PV NA OBSZARZE 2 W PODZIALE NA GODZINY	88
RYS. 5.7. BŁĘDY PROCENTOWE GENERACJI PV NA OBSZARZE 2 W PODZIALE NA MIESIĄCE	89
RYS. 5.8. DWUTYGODNIOWA PROGNOZA I WYKONANIE RZECZYWISTE ORAZ ODCHYLENIA PROGNOZY NA OBSZARZE WROCLAW	89
RYS. 5.9. ROZKŁAD BŁĘDÓW GENERACJI PV NA OBSZARZE 1	90
RYS. 5.10. BŁĘDY PROCENTOWE GENERACJI PV NA OBSZARZE 1 W PODZIALE NA GODZINY	90
RYS. 5.11. BŁĘDY PROCENTOWE GENERACJI PV NA OBSZARZE 1 W PODZIALE NA MIESIĄCE	91
RYS. 5.12. DWUTYGODNIOWA PROGNOZA I WYKONANIE RZECZYWISTE ORAZ ODCHYLENIA PROGNOZY NA OBSZARZE 1	91
RYS. 5.13. ROZKŁAD BŁĘDÓW ZAPOTRZEBOWANIA BRUTTO NA OBSZARZE 3	93
RYS. 5.14. AUTOKORELACJA RESZT MODELU ENSEMBLE ZAPOTRZEBOWANIA BRUTTO NA OBSZARZE 3	93
RYS. 5.15. DWUTYGODNIOWA PROGNOZA I WYKONANIE RZECZYWISTE ZAPOTRZEBOWANIA NETTO ORAZ ODCHYLENIA NA OBSZARZE 3	95
RYS. 5.16. DWUTYGODNIOWA PROGNOZA I WYKONANIE RZECZYWISTE ZAPOTRZEBOWANIA NETTO ORAZ ODCHYLENIA NA OBSZARZE 2	96
RYS. 5.17. DWUTYGODNIOWA PROGNOZA I WYKONANIE RZECZYWISTE ZAPOTRZEBOWANIA NETTO ORAZ ODCHYLENIA NA OBSZARZE 1	96
RYS. 5.18. BŁĘDY PROCENTOWE ZAPOTRZEBOWANIA NETTO NA OBSZARZE 3 W PODZIALE NA GODZINY	97

RYS. 5.19. BŁĘDY PROCENTOWE ZAPOTRZEBOWANIA NETTO NA OBSZARZE 2 W PODZIALE NA GODZINY	97
RYS. 5.20. BŁĘDY PROCENTOWE ZAPOTRZEBOWANIA NETTO NA OBSZARZE 1 W PODZIALE NA GODZINY	98
RYS. 5.21. KORELACJA POMIĘDZY ENERGIĄ ODDANĄ DO SIECI PRZEZ PROSUMENTÓW A PROGNOZĄ GHI RÓŻNYCH DOSTAWCÓW PROGNOZ METEOROLOGICZNYCH	99
RYS. 5.22. KORELACJA POMIĘDZY GENERACJĄ PV A PROGNOZĄ GHI RÓŻNYCH DOSTAWCÓW PROGNOZ METEOROLOGICZNYCH.....	99
RYS. 5.23. ANALIZA WARIANCJI ANOVA DLA GENERACJI PV I PROGNOZ GHI RÓŻNYCH DOSTAWCÓW PROGNOZ METEOROLOGICZNYCH	100
RYS. 5.24. WYNIKI TESTU ANOVA DLA PROGNOZ GENERACJI PV NA PODSTAWIE PROGNOZ GHI RÓŻNYCH DOSTAWCÓW	101
RYS. 5.25. PORÓWNANIE ODCHYLEŃ PROGNOZ GENERACJI PV, OBLICZONYCH NA PODSTAWIE PROGNOZ GHI RÓŻNYCH DOSTAWCÓW PROGNOZ METEOROLOGICZNYCH.....	102
RYS. 5.26. SCHEMAT ARCHIWIZACJI DANYCH ZAPOTRZEBOWANIA W CELU ZBADANIA ZMIENNOŚCI W UDOSTĘPNIANYCH PRZEZ OSD DANYCH RZECZYWISTYCH DO PROGNOZOWANIA.....	104
RYS. 5.27. ŚREDNIE GODZINOWE ODCHYLENIE DANYCH UDOSTĘPNIANYCH PRZEZ OSD NA OBSZARZE 1	106
RYS. 5.28. ŚREDNIE GODZINOWE ODCHYLENIE DANYCH UDOSTĘPNIANYCH PRZEZ OSD NA OBSZARZE 2	107
RYS. 5.29. ŚREDNIE GODZINOWE ODCHYLENIE DANYCH UDOSTĘPNIANYCH PRZEZ OSD NA OBSZARZE 3	107
RYS. 7.1. ZIDENTYFIKOWANE, W RAMACH PRAC BADAWCZYCH, RYZYKO I WYZWANIA STOJĄCE PRZED SPÓŁKĄ OBROTU	111

Spis Tabel

TAB. 2.1 DOSTAWCY POPULARNYCH MODELI METEOROLOGICZNYCH	23
TAB. 2.2. ZESTAWIENIE WYNIKÓW PODOBIENSTWA DNI TYGODNIA, UŻYWANE W METODZIE DNIA PODOBNEGO	33
TAB. 3.1. ZMIANY PROCENTOWE W ZAPOTRZEBOWANIU NA ENERGIĘ ELEKTRYCZNĄ, NA WYBRANYM OBSZARZE	51
TAB. 3.2. UDZIAŁ MOCY ZAINSTALOWANEJ W MIKROINSTALACJACH FOTOWOLTAICZNYCH ORAZ W GENERACJI NA OBSZARZE GLIWICE, W PODZIALE NA REJONY	57
TAB. 3.3. GEOGRAFICZNE ROZMIESZCZENIE MIKROINSTALACJI PRZYŁĄCZONYCH DO POSZCZEGÓLNYCH REJONÓW DYSTRYBUCYJNYCH WRAZ Z MOCĄ ZAINSTALOWANĄ INSTALACJI PV	59
TAB. 5.1. PORÓWNANIE WYNIKÓW PROGNOZ GENERACJI PV Z RÓŻNYCH MODELI NA PROGNOZOWANYCH OBSZARACH.....	84
TAB. 5.2. PORÓWNANIE WYNIKÓW PROGNOZ ZAPOTRZEBOWANIA BRUTTO Z RÓŻNYCH MODELI NA PROGNOZOWANYCH OBSZARACH.....	92
TAB. 5.3. PORÓWNANIE WYNIKÓW PROGNOZ BRUTTO Z MODELEM REFERENCYJNYM NA OBSZARACH	94
TAB. 5.4. NUMERACJA RÓŻNYCH MODELI POGODOWYCH, WYKORZYSTANYCH W BADANIU KORELACJI POMIĘDZY GENERACJĄ PV A NATĘŻENIEM PROMIENIOWANIA SŁONECZNEGO	98
TAB. 5.5. WYNIKI ANALIZY ANOVA DLA GENERACJI PV I PROGNOZ GHI RÓŻNYCH DOSTAWCÓW PROGNOZ METEOROLOGICZNYCH.....	101
TAB. 5.6. PORÓWNANIE ODCHYLEŃ DANYCH RZECZYWISTYCH W 2024 ROKU, UDOSTĘPNIANYCH Z RÓŻNYM OPÓŹNIENIEM, W PODZIALE NA OBSZAR KRAKÓW, WROCŁAW I GLIWICE	104
TAB. 5.7. PORÓWNANIE ODCHYLEŃ DANYCH RZECZYWISTYCH W 2023 ROKU, UDOSTĘPNIANYCH Z RÓŻNYM OPÓŹNIENIEM, W PODZIALE NA OBSZAR KRAKÓW, WROCŁAW I GLIWICE	105
TAB. 5.8. PORÓWNANIE ODCHYLEŃ DANYCH RZECZYWISTYCH W 2022 ROKU, UDOSTĘPNIANYCH Z RÓŻNYM OPÓŹNIENIEM, W PODZIALE NA OBSZAR KRAKÓW, WROCŁAW I GLIWICE	105
TAB. 5.9. PORÓWNANIE KOSZTU BILANSOWANIA METODY BRUTTO I MODELU REFERENCYJNEGO	109

ZAŁĄCZNIKI

Kody Matlab

Test Diebolda-Mariano

```
%Sprawdzeniu podlegają tylko wartości ER
większe od 0
testy=testy(testy.ER>0,:)
rzeczywiste = testy.ER'; % Rzeczywiste wartości
prognozy1 =
testy.KrzywaSprawno_ciFarmyPVKrakowDTN';
% Prognozy 1
prognozy2
=testy.KrzywaSprawno_ciFarmyPVSredWaz';
% Prognozy 2
% Obliczanie błędów prognoz
blad1 = rzeczywiste - prognozy1;
blad2 = rzeczywiste - prognozy2;
% Obliczanie różnic błędów
roznice = blad1.^2 - blad2.^2 ;
% Test Diebold-Mariano
n = length(roznice);
srednia_roznic = mean(roznice);
wariancja_roznic = var(roznice);
statystyka = (srednia_roznic /
sqrt(wariancja_roznic / n));
% Wartość p (przy założeniu normalności)
p_value = 2 * (1 - normcdf(abs(statystyka)));
fprintf('Statystyka testu: %.4f', statystyka);
fprintf('Wartość p: %.4f', p_value);
figure;
bar(roznice);
title('Różnice błędów prognoz');
xlabel('Observacje');
ylabel('Różnica błędów');
grid on;
```

Test wariancji Annova

```
cd 'C:\Users\pmachal\OneDrive -
Tauron\Dokumenty\MATLAB\!Praca\testyDieb
old'
clear
testy=readtable("doTestówDiebold.xlsx");
% Do sprawdzenia czy tam gdzie generacja jest
0 test jest taki sam
% testy(testy.ER==0,:);
grupa1 = testy.ER'
grupa2 =
testy.KrzywaSprawno_ciFarmyPVKrakowDTN'
grupa3 =
testy.KrzywaSprawno_ciFarmyPVKrakowIMG
W'
grupa4 =
testy.KrzywaSprawno_ciFarmyPVKrakowICON
'
grupa5 =
testy.KrzywaSprawno_ciFarmyPVKrakowGFS'
grupa6 =
testy.KrzywaSprawno_ciFarmyPVKrakowICM'
grupa7 =
testy.KrzywaSprawno_ciFarmyPVSredWaz'
grupa8 = testy.ER'
% Łączenie danych
dane = [grupa1, grupa2, grupa3, grupa4, grupa5,
grupa6, grupa7, grupa8];
grupy = [repmat({'ER'}, 1, length(grupa1)), ...
repmat({'Prognoza 1'}, 1, length(grupa2)), ...
repmat({'Prognoza 2'}, 1, length(grupa3)), ...
repmat({'Prognoza 3'}, 1, length(grupa4)), ...
repmat({'Prognoza 4'}, 1, length(grupa5)), ...
```

```

repmat({'Prognoza 5'}, 1, length(grupa6)), ...
repmat({'Prognoza 6'}, 1, length(grupa7)), ...
repmat({'Prognoza 7'}, 1, length(grupa8));
% Analiza wariancji
[p, tbl, stats] = anova1(dane, grupy);
% Testy wielokrotne
figure;
multcompare(stats);

```

Generacja profilu brutto

```

clear
Obszar="Wroclaw"
addpath 'C:\Users\pmachal\OneDrive -
Tauron\Dokumenty\MATLAB\Analiza profili'
addpath 'C:\Users\pmachal\OneDrive -
Tauron\Dokumenty\MATLAB'
[Dane, NatProm, Prognozy] = import(Obszar)
[training_data, test_data] = walidacja(Dane)
%[MdlReg] = ModelAuto (training_data,
test_data, Dane)
[modelSSN] = ModelSSN(training_data,
test_data, Dane)
% [modelSSN2] = ModelSSN(training_data,
test_data, Dane)
[PVSSN, Prognozy] = Korekta(modelSSN,
Prognozy, NatProm)
% [PVSSN2] = Korekta(modelSSN, Prognozy,
NatProm)
GenerujBruttoPV(PVSSN, Prognozy, Obszar)
[WynikiZapNet] =
StepwiseRegressionPM(Dane)

```

Import danych

```

function [Dane, NatProm, Prognozy] =
import(Obszar)

```

```

StartTimeP=datetime(2016,1,1,0,0,0);
EndTimeP=datetime(2019,12,31,23,59,0);
timestep=60;
%create a time vector for prediction with 1-hour
resolution
TimeP=StartTimeP:minutes(timestep):EndTime
P;
% Import the data
sciezka = append('C:\Users\pmachal\OneDrive -
Tauron\Dokumenty\MATLAB\Analiza profili',
'\', Obszar)
cd(sciezka);
NazwaplikuImport = append(Obszar,
'DaneZapotrzebowanie.xlsx');
Dane = readtable(NazwaplikuImport);
Prognozy = Dane(52609:end,1:15);
Dane = Dane(1:35064,1:15);
%Dane.DataMatlabUTC = datetime(TimeP',
'TimeZone','Z') ;
NazwaplikuImport = append(Obszar,
'NatezenieProm.xlsx');
NatProm = readtable(NazwaplikuImport);
StartTimeP=datetime(2022,1,1,0,0,0);
EndTimeP=datetime(2024,09,26,22,59,0);
timestep=60;
%create a time vector for prediction with 1-hour
resolution
TimeP=StartTimeP:minutes(timestep):EndTime
P;
% dtLCL = datetime('now', 'TimeZone','local')%
Current Local Time
% dtUTC = datetime(dtLCL, 'TimeZone','Z') %
Current UTC Time
NatProm.DataMatlabUTC = datetime(TimeP',
'TimeZone','Z') ;
end

```

Walidacja i normalizacja

```
function [training_data, test_data] =
walidacja(Dane)

% Cross variation (train: 70%, test: 30%)
cv = cvpartition(size(Dane,1),'HoldOut',0.3);
idx = cv.test;

% Separate to training and test data
training_data = Dane(~idx,:);
test_data = Dane(idx,:);
end
```

Model SSN

```
function [modelSSN] =
ModelSSN(training_data, test_data, Dane)
setdemorandstream(491218382)
training_data=table2array(training_data);
test_data = table2array(test_data);
all = table2array(Dane);

% Build a neural network
modelSSN = TrainSSN(training_data(1:end-1,:),training_data(end, :))

% Predict the test data
NetOutput= modelSSN(test_data(1:end-1,:));

NetOutputTrain =
modelSSN(training_data(1:end-1,:));
NetOutputAll = modelSSN(all(1:end-1,:));
scatter(NetOutput, test_data(end,:))
title('SSN Model')

%(training_data(:, 1), training_data(:, 2), ...

% Evaluate the model
mse = mean((NetOutput - test_data(end, :)).^2);

% Plot the data and the predictions
plot([training_data(end, :); NetOutputTrain])
plot([test_data(end, :); NetOutput])
legend('data', 'prediction')
title('SSN Training Data and Predictions')
```

```
xlabel('data')
ylabel('Wolumen [MWh]')
plot([all(end, :); NetOutputAll])
legend('data', 'prediction')
title('SSN Model All')
xlabel('data')
ylabel('Wolumen [MWh]')
[OdchyleniaSSN, BledySrednieSSN] =
Odchylenia(NetOutputAll', Dane.ER)
BledySrednieSSN(:, 5:6)
end
```

TrainSSN

```
function [net,tr, y] = TrainSSN(TblSSNinput,
TblSSNtarget)

% This script assumes these variables are
defined:

%
% TblSSNinput - input data.
% TblSSNtarget - target data.
x = TblSSNinput;
t = TblSSNtarget;

% Choose a Training Function

% For a list of all training functions type: help
ntrain

% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for
challenging problems.
% 'trainscg' uses less memory. Suitable in low
memory situations.

trainFcn = 'trainlm';% Bayesian Regularization
backpropagation.

% Create a Fitting Network
hiddenLayerSize = [10 10 10 10 10];
net = fitnet(hiddenLayerSize,trainFcn);

% Setup Division of Data for Training,
Validation, Testing
net.divideParam.trainRatio = 95/100;
```

```

net.divideParam.valRatio = 5/100;
net.divideParam.testRatio = 5/100;
% Train the Network
[net,tr] = train(net,x,t);
% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)
% View the Network
%view(net)

% Plots
% Uncomment these lines to enable various
plots.
% figure, plotperform(tr)
% figure, plottrainstate(tr)
% figure, ploterrhist(e)
figure, plotregression(t,y)
% figure, plotfit(net,x,t)
end

```

Korekta poziomu zapotrzebowania

```

function [PVSSN, Prognozy] =
Korekta(modelSSN, Prognozy, NatProm)
PrognozySSNWej = table2array(Prognozy)';
PrognozySSNWyj =
modelSSN(PrognozySSNWej(1:end-1,:));
PrognozaSSN = PrognozySSNWyj()
t= NatProm.DataMatlabUTC;
DzienTyg= weekday(t); % 1 niedziela 7 sobota
NrTyg = week(t);
Rok = year(t);
Miesiac=month(t);
Dzien=day(t);
Godzina = hour(t);
Dzien2=t;

```

```

Dzien2.Format = 'dd-MMM-yyyy';
[OdchyleniaBezIRR2023,
BledySrednieBezIRR2023] =
Odchylenia(PrognozySSNWyj', Prognozy.ER)
ErrAnal = table(t, Miesiac, NrTyg, DzienTyg,
Dzien, Dzien2, Godzina, Rok);
Prognozy = [Prognozy, ErrAnal];
%oblicz różnice poziomów tam gdzie nie było
nasłonecznienia
idx3 = NatProm.NatProm==0;
NatProm.Oddanie(idx3) = 0;
ErrAnal = [ErrAnal(idx3, :),
OdchyleniaBezIRR2023(idx3,2),
OdchyleniaBezIRR2023(idx3,3),
Prognozy(idx3, 9)]
ErrAnal.Properties.VariableNames{'t'} = 'Time';
%MAPE beze godzin nasł, tylko do sprawdzenia
mean(OdchyleniaBezIRR2023.MAPE(idx3))
Gdzien =
groupsummary(ErrAnal,{'Rok','Miesiac',
'Dzien'}, "mean", 'MPE',
"IncludeEmptyGroups",false)
i = height(Gdzien)
idx = NatProm.NatProm==0;
korekta = zeros(1,length(idx));
for i = 1:i
idx = (year(t)== Gdzien.Rok(i) & month(t)==
Gdzien.Miesiac(i) & day(t)== Gdzien.Dzien(i));
PrognozaSSN(idx) =
PrognozySSNWyj(idx)'*(1+(Gdzien.mean_MPE
(i)*-1)/100);
korekta(idx) = (Gdzien.mean_MPE(i)*-1)/100;
end
%Jakie błędy po korekcie w godzinach bez
nasłonecznienia
% [a, b] = Odchylenia(PrognozaSSN(idx3),
Prognozy.ER(idx3))
%dla sprawdzenia czy jest korelacja
współczynnika korekty z temperatura
% korekta(:,[2:3]) = [Prognozy.Tmax,
Prognozy.Tmin];
close all

```

```

plot(Prognozy.t, ([PrognozaSSN,
PrognozySSNWyj]))
legend('Po korekcie', 'Przed korektą')
PVSSN = (PrognozaSSN)-Prognozy.ER;
%Gdzie nie ma nasłonecznienia tam nie ma
generacji
PVSSN(idx3)=0;
%Gdzie generacja ujemna tam przyjmij oddanie
PVSSN(PVSSN<0) =
NatProm.Oddanie(PVSSN<0)*1.2
%Gdzie generacja mniejsza od oddania tam
przyjmij oddanie+20%
PVSSN(PVSSN<NatProm.Oddanie) =
NatProm.Oddanie(PVSSN<NatProm.Oddanie)*
1.2
%Narysowanie wykresów do wizualnej oceny
prawidłowości danych
figure, plot(Prognozy.t, korekta)
title('Korekta')
ylabel(['%'])
figure, plot(Prognozy.t, [PrognozaSSN,
Prognozy.ER, PrognozySSNWyj])
title('Prognoza po korekcie, dane rzeczywiste,
prognoza przed korektą')
ylabel(['MWh'])
legend('SSN po korekcie', 'ER', 'SSN przed
korektą')
figure, gscatter( (PVSSN), NatProm.Oddanie,
year(NatProm.DataMatlabUTC))
title('Energy to grid vs PV generation')
xlabel('PV generation [MWh]')
ylabel('Energy to grid [MWh]')
figure, plot(t, [NatProm.Oddanie,(PVSSN),
NatProm.MocZainstalowanaMW])
legend('Energy to grid [MWh]', 'PV generation
[MWh]', 'Moc zainstalowana [MWp]')
title('Energy to grid vs PV generation vs
Installed power')
xlabel('Time')
ylabel(' [MWh]')
figure, gscatter(NatProm.NatProm,
(PVSSN),year(NatProm.DataMatlabUTC))

```

```

title('GHI vs PV generation')
xlabel('GHI [Wm^-2]')
ylabel('PV generation [MWh]')
stackedplot( table(korekta*100, Prognozy.ER,
PrognozaSSN, PVSSN, ...
'VariableNames', {'Korekta','Zapotrzebowanie
netto','Zapotrzebowanie brutto','Generacja
PV'}));
PVSSN2 = table(PVSSN, Rok, Miesiac,
Godzina, NatProm.NatProm/900,
NatProm.Oddanie, ...
'VariableNames', {'PVSSN','Rok','Miesiac',
'Godzina', 'NatProm', 'Oddanie'});
MocMaxPV =
groupsummary(PVSSN2,{'Rok','Miesiac'},
"max", ["PVSSN", "NatProm"],
"IncludeEmptyGroups",false)
MocMaxPV.MocPvKorekta =
MocMaxPV.max_PVSSN./MocMaxPV.max_Na
tProm
MocMaxPV.GroupCount=[];
end

```

Obszar PV i zapotrzebowania brutto

```

function [] = GenerujBruttoPV(PVSSN,
Prognozy, Obszar)
Brutto = table(Prognozy.t,
PVSSN+Prognozy.ER, PVSSN);
Brutto.Properties.VariableNames = {'Time',
'ER_Brutto','SzacowanaGeneracjaPV'};
%zapisz wyniki dla SF
writetable(Brutto, Obszar+"Wynik Profil
Brutto.xlsx", "WriteRowNames",true)
winopen(Obszar+"Wynik Profil Brutto.xlsx")
end

```