



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

DZIEDZINA nauk inżynieryjno-technicznych

DYSCYPLINA inżynieria mechaniczna

ROZPRAWA DOKTORSKA

*Wykorzystanie zaawansowanych algorytmów analizy
danych dla optymalizacji procesów produkcyjnych
w technologiach energetycznych*

Autor: Maciej Bujalski

Promotor rozprawy: dr hab. inż. Paweł Madejski, prof. AGH

Promotor pomocniczy: dr inż. Krzysztof Fuzowski

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie, Szkoła Doktorska

Kraków, 2024



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

FIELD OF SCIENCE engineering and technical sciences

SCIENTIFIC DISCIPLINE Mechanical Engineering

DOCTORAL DISSERTATION

*The use of advanced data analysis algorithms for
optimization of production processes in energy
technologies*

Author: Maciej Bujalski

First supervisor: dr hab. inż. Paweł Madejski, prof. AGH
Second supervisor or Auxiliary supervisor: dr inż. Krzysztof Fuzowski

Completed at: AGH University of Science and Technology, Doctoral School

Kraków, 2024

Niniejsza praca powstała w związku z realizacją III edycji programu Ministra Edukacji i Nauki pn. „Doktorat Wdrożeniowy”, w ramach współpracy pomiędzy Akademią Górniczo-Hutniczą im. Stanisława Staszica w Krakowie, a przedsiębiorstwem zatrudniającym Doktoranta - PGE Energia Ciepła S.A.

Promotorowi rozprawy prof. Pawłowi Madejskiemu
oraz promotorowi pomocniczemu dr Krzysztofowi Fuzowskiemu,
pragnę złożyć podziękowanie za okazaną mi życzliwość, cierpliwość
i opiekę naukową.

Spis treści

Spis treści	5
Streszczenie	7
Abstract	8
1 Wprowadzenie.....	9
2 Dotychczasowy stan zagadnienia	11
2.1 Stan zagadnienia w zakresie prognozowania zapotrzebowania na ciepło...13	
2.2 Stan zagadnienia w zakresie prognozowania parametrów produkcyjnych turbiny gazowej	15
2.3 Stan zagadnienia w zakresie optymalizacji produkcji w dobie następnej..17	
3 Cel, teza oraz zakres pracy	19
4 Opis obiektu badań.....	22
4.1 Sieć ciepłownicza	22
4.2 Elektrociepłownia gazowa	28
4.2.1 Opis technologii.....	29
4.2.2 Turbina gazowa	31
4.2.3 Kocioł odzysknicowy	32
4.2.4 Akumulator ciepła.....	34
4.2.5 Kocioł wodny (szczytowy).....	35
4.3 Produkcja ciepła i energii elektrycznej w elektrociepłowni.....	35
5 Prognozowanie zapotrzebowania na ciepło metodami uczenia nadzorowanego.....	40
5.1 Dane uczące model predykcyjny	40
5.1.1 Dokładność prognozy danych pogodowych.....	45
5.2 Uogólniony Model Addytywny GAM.....	47
5.2.1 Przykład wykorzystania algorytmu GAM do prognozy mocy cieplnej	50
5.3 Model prognozowania zapotrzebowania na ciepło w sezonie grzewczym ...53	
5.3.1 Wyniki prognozowania zapotrzebowania na ciepło.....	56
5.4 Model prognozowania zapotrzebowania na ciepło poza sezonem grzewczym 65	
5.4.1 Wyniki prognozowania zapotrzebowania na ciepło.....	69
6 Modelowanie pracy turbiny gazowej z kotłem odzysknicowym.....	72
6.1 Model turbiny gazowej i kotła odzysknicowego.....	72

6.1.1	Metoda kalibracji modelu turbiny gazowej w oparciu o dane ruchowe...	82
6.2	Prognozowanie pracy turbiny gazowej i kotła odzysknicowego	90
6.2.1	Wyniki prognozowania parametrów pracy turbiny i kotła.....	95
7	Weryfikacja wyników prognozowania zapotrzebowania na ciepło i parametrów produkcyjnych turbin gazowych.....	98
7.1	Weryfikacja modelu zapotrzebowania na ciepło.....	98
7.2	Weryfikacja modelu turbiny gazowej z kotłem odzysknicowym	100
8	Optymalizacja produkcji ciepła w dobie następnej	109
8.1	Wyniki optymalizacji produkcji w dobie następnej	111
9	Ogólna koncepcja wdrożenia wyników	119
10	Wnioski i uwagi końcowe	122
	Wykaz ważniejszych skrótów, oznaczeń i symboli	126
	Bibliografia	128

Streszczenie

Rozprawa dotyczy problemu optymalizacji procesu planowania pracy elektrociepłowni gazowej w krótkoterminowym horyzoncie czasowym, obejmującym dobę następną. Rozważana elektrociepłownia jest częścią systemu ciepłowniczego zlokalizowanego w Toruniu. Wyposażona jest m.in. w dwie jednakowe, kogeneracyjne turbiny gazowe z odzyskiem ciepła w wodnych kotłach odzysknicowych oraz akumulator ciepła. Łączna zainstalowana moc elektryczna i cieplna elektrociepłowni wynosi odpowiednio 107,1 MWe i 357,6 MWt. Celem pracy jest opracowanie narzędzia analitycznego, przeznaczonego do krótkoterminowego planowania pracy badanej elektrociepłowni, przy uwzględnieniu maksymalizacji funkcji celu określającej umowny zysk operacyjny. Zakładanym efektem końcowym rozprawy jest praktyczne zastosowanie wyników prac naukowo-badawczych poprzez wdrożenie narzędzia w przedsiębiorstwie zatrudniającym Autora, w związku z realizacją programu „Doktorat Wdrożeniowy”. Integralną częścią narzędzia jest model prognozowania zapotrzebowania na ciepło oddawane przez źródło do sieci ciepłowniczej. Model predykcyjny oparto o metodę uczenia maszynowego - nadzorowanego. Przedstawiono dyskusję otrzymanych wyników w postaci dokładności godzinowych prognoz mocy cieplnej. W rezultacie, średni błąd względny modelu wyniósł ok. 8,5% i ok. 4% odpowiednio podczas sezonu grzewczego i poza nim. Następnie, przedstawiono model do obliczania w rozdzielczości godzinowej parametrów produkcyjnych kogeneracyjnych turbin gazowych: godzinowej produkcji energii elektrycznej, produkcji ciepła w kotle odzysknicowym i zużycia paliwa gazowego. Omówiono przyjęty sposób kalibracji modelu termodynamicznego z użyciem rzeczywistych danych procesowych. Zastosowanie regresyjnych metod uczenia nadzorowanego pozwoliło na poprawę dokładności prognozowania parametrów produkcyjnych turbin gazowych. Średnioroczna dokładność prognozy w dobie następnej dla mocy elektrycznej, mocy cieplnej i zużycia paliwa gazowego wyniosła odpowiednio ok. 1,5%, 1,2% i 0,4%. Do opracowania modeli predykcyjnych zapotrzebowania na ciepło oraz parametrów produkcyjnych turbin zastosowano algorytm Uogólnionego Modelu Addytywnego GAM (ang. Generalized Additive Model). W rozprawie przedstawiono moduł do optymalizacji pracy elektrociepłowni umożliwiający zaplanowanie pracy jednostek wytwórczych pracujących na sieć ciepłowniczą, z charakterystyką przyjętej funkcji celu określającej umowny zysk operacyjny elektrociepłowni. W oparciu o wyniki prognoz zapotrzebowania na ciepło oraz parametrów produkcyjnych jednostek wytwórczych zostały przedstawione scenariusze produkcyjne w horyzoncie doby następnej (jako wynik działania optymalizatora), dla wybranych dni z okresu zimowego, przejściowego oraz letniego.

Abstract

The paper concerns the problem of short-term planning the operation of a gas-fired combined heat and power plant (CHP). The considered CHP plant is a part of the district heating system located in Toruń (Poland). The plant consist of two identical, cogeneration gas turbines equipped with heat recovery hot water boilers as well as heat accumulator. The total installed electrical and thermal capacity of the CHP plant is 107,1 MWe and 357,6 MWt, respectively. The aim of the work is to develop an analytical tool for day ahead planning of the examined CHP plant, taking into account the maximization of the operating profit. The outcome of the work has been implemented in the company employing the Author, in connection with the "Implementation Doctorate" program. An integral part of the developed tool is heat demand forecasting model in the district heating network. The next chapter discusses predictive model that is based on the regression supervised machine learning technique. The method of training the model, along with the results obtained in the form of the accuracy of hourly heat power forecasts. As a result, the average relative error of the model was approximately 8.5% and 4% during and outside the heating season, respectively. Then, a thermodynamic model of gas turbine with heat recovery in hot water boiler was presented. The simulation model is used for forecasting the production parameters of cogeneration gas turbines in day ahead time horizon. The following parameters can be obtained: electricity production, recovered heat from flue gas and natural gas fuel consumption. The way of calibrating the thermodynamic model based on real process data was discussed. The use of regression supervised learning methods allowed to improve the accuracy of forecasting parameters important for production optimization. The average annual forecast accuracy in the next day for electric power, thermal power and gas fuel consumption was approximately 1.5%, 1.2% and 0.4%, respectively. The Generalized Additive Model (GAM) algorithm was used to develop predictive models. The dissertation presents a module for optimizing the production process in the CHP plant, with the characteristics of the adopted objective function describing the operating profit. Based on the results of heat demand and gas turbine production parameters forecasts, operational scenarios were presented for the upcoming day (as a result of the optimizer's operation), for selected days in the winter, transitional and summer periods.

1 Wprowadzenie

Kluczowym elementem zwiększania efektywności technicznej i ekonomicznej w technologiach energetycznych jest optymalizacja procesu produkcyjnego. Zarządzanie procesem produkcji energii w zadanym układzie technologicznym, ma z punktu widzenia wytwórcy zmierzać do uzyskania możliwie najwyższego poziomu zysku operacyjnego oraz jak najniższego negatywnego wpływu na środowisko naturalne. Wymienione efekty są spełnione w przypadku, gdy układ technologiczny pracuje z najwyższą możliwą do uzyskania w danych warunkach sprawnością. Jednocześnie, na etapie optymalizacji należy brać pod uwagę szereg warunków brzegowych związanych z czynnikami technologicznymi, środowiskowymi i rynkowymi [1]. Optymalizacja procesów produkcyjnych w energetyce jest szerokim zagadnieniem i jest stosowana na etapie projektowania źródeł wytwórczych [2] oraz podczas ich bieżącej eksploatacji [3]. Optymalizacja pracy jednostek wytwórczych ma szczególne znaczenie w przypadku elektrociepłowni pracującej w obrębie systemu ciepłowniczego, bowiem przychody operacyjne uzyskiwane są zarówno z produkcji ciepła jak i energii elektrycznej. Skojarzona gospodarka energetyczna, polegająca na równoczesnym wytwarzaniu ciepła i energii elektrycznej podczas tego samego procesu technologicznego jest efektywnym procesem wytwarzania energii, korzystnym pod względem ekologicznym i ekonomicznym [4]. Nieodłącznym elementem systemu ciepłowniczego, oprócz źródeł ciepła i sieci ciepłowniczej są odbiorcy końcowi, do których dostarczane jest ciepło pod postacią wody sieciowej. Taka forma wytwarzania energii jest bardzo rozpowszechniona w dużych ośrodkach miejskich w Polsce. W 2021 roku udział ciepła pochodzącego z kogeneracji wynosił 65,2% krajowej produkcji ciepła ogółem i był większy o 2,4 punktu procentowego w porównaniu z rokiem poprzednim [5]. Polski rynek ciepła systemowego jest drugim co do wielkości w Unii Europejskiej, a łączna długość sieci ciepłowniczych wynosi ponad 21 tys. km. Z ciepła systemowego korzysta ponad 16 mln mieszkańców. Bardzo szybka zmiana otoczenia regulacyjnego i warunków rynkowych w ciepłownictwie zmusza do weryfikowania dotychczasowych strategii i planów inwestycyjnych. Ciepłownictwo systemowe w Polsce mierzy się obecnie z wyzwaniami związanymi z koniecznością przyspieszenia transformacji energetycznej w związku z odejściem od spalania paliwa węglowego. Konwencjonalne siłownie cieplne będą zastępowane innymi jednostkami wytwórczymi, charakteryzującymi się niskimi bądź zerowymi wskaźnikami emisyjności gazów cieplarnianych. Z uwagi na restrykcyjne uwarunkowania dotyczące spełnienia kryteriów efektywnego systemu ciepłowniczego, do wytwarzania ciepła sieciowego, będą na coraz szerszą skalę stosowane Odnawialne Źródła Energii, jak m.in. wielkopowierzchniowe farmy kolektorów słonecznych, pompy ciepła odzyskujące energię z rzek, ścieków oczyszczonych, źródeł geotermalnych [6][7]. Zgodnie z Dyrektywą EED stanowiącą element strategii Unii Europejskiej, system ciepłowniczy będzie uznany za efektywny w latach 2028-2034, jeśli udział produkcji ciepła przekroczy co najmniej 50% z energii odnawialnej lub ciepła odpadowego, bądź 80% z wysokosprawnej kogeneracji. Alternatywnym warunkiem jest udział 50%

z kombinacji tych trzech źródeł ciepła, przy czym minimalny udział z Odnawialnych Źródeł Energii wyniesie 5%. Integracja w systemach ciepłowniczych Odnawialnych Źródeł Energii wymusza konieczność ich modernizacji w kierunku układów rozproszonych z magazynami ciepła, niskotemperaturowymi ciepłociągami [8]. Jednocześnie, stanowi to wyzwanie z punktu widzenia optymalizacji pracy istniejących, konwencjonalnych źródeł współpracujących z siecią ciepłowniczą, biorąc pod uwagę konieczność ich współpracy z nowymi jednostkami w ramach systemu ciepłowniczego.

W polskich uwarunkowaniach, w najbliższej perspektywie paliwo gazowe będzie prawdopodobnie paliwem przejściowym w procesie osiągnięcia pełnej neutralności klimatycznej ciepłownictwa [9]. Przeprowadzone w ostatnich latach nowe inwestycje w zakresie modernizacji istniejących zakładów, bądź budowy nowych, zakładały wykorzystanie kotłów, kogeneracyjnych silników bądź turbin gazowych. Układy bazujące na turbinach gazowych w układzie prostym z wodnym kotłem odzysknicowym lub w układzie gazowo-parowym wykazują szereg zalet: wysoka sprawność konwersji energii chemicznej paliwa, niskie emisje substancji szkodliwych dla środowiska, elastyczność produkcji, możliwość szybkiej i częstej zmiany obciążenia i krótkie czasy rozruchu [10]. Gazowe źródła wytwórcze mogą efektywnie współpracować ze niestabilnymi i pogodowo zależnymi źródłami odnawialnymi, stanowiąc zabezpieczenie dostaw ciepła dla systemu ciepłowniczego.

Działalność operacyjna elektrociepłowni wynika głównie z uwarunkowań lokalnego rynku ciepła, który determinuje poziom zapotrzebowania na moc cieplną. Dodatkowym uwarunkowaniem wpływającym na możliwość maksymalizacji przychodów operacyjnych jest udział elektrociepłowni w rynku energii elektrycznej. Sprzedaż energii na giełdowym Rynku Dnia Następnego (RDN) jest związana z koniecznością kontraktowania godzinowych wolumenów produkcji energii elektrycznej w dobie poprzedzającej realizację. Zarządzanie pracą elektrociepłowni w aktualnych warunkach rynkowych i środowiskowych jest problemem trudnym, przed którym staje coraz więcej przedsiębiorstw energetycznych [11].

W niniejszej pracy przedstawiono propozycje rozwiązania problemu krótko-terminowego (w horyzoncie doby następnej) planowania pracy elektrociepłowni gazowej współpracującej z miejską siecią ciepłowniczą, wyposażonej w dwie kogeneracyjne turbiny gazowe z odzyskiem ciepła w wodnym kotle odzysknicowym. Prace naukowo-badawcze zmierzały do opracowania narzędzia służącego do symulacji pracy elektrociepłowni w zakładanym horyzoncie czasowym. Narzędzie w swojej funkcjonalności umożliwi zaplanowanie optymalnego scenariusza pracy elektrociepłowni, uwzględniając uwarunkowania sprzedaży energii elektrycznej na RDN. Na etapie opracowania narzędzia szczególną uwagę poświęcono możliwościom zastosowania zaawansowanych algorytmów analizy danych na potrzeby uzyskania wysokiej dokładności w prognozowaniu istotnych dla procesu planowania pracy parametrów.

2 Dotychczasowy stan zagadnienia

Zagadnienie optymalizacji pracy systemu ciepłowniczego dotyczy wszystkich jego elementów, tj. źródeł ciepła, sieci ciepłowniczej i węzłów ciepłowniczych [12]. Jak wskazują Kazda i in. [13], optymalizacja pracy źródeł ciepła jest związana z problemem ustalenia strategii pracy jednostek wytwórczych, która zapewni osiągnięcie najwyższego zysku operacyjnego, przy spełnieniu uwarunkowań związanych ze współpracą z siecią ciepłowniczą, pod kątem zabezpieczenia dostaw ciepła na wymaganym poziomie ilościowym (w zakresie wolumenu ciepła) i jakościowym (odpowiedniej temperatury nośnika ciepła). Optymalizacja pracy sieci ciepłowniczej polega w głównej mierze na kontroli parametrów pracy w zakresie temperatur i przepływów wody sieciowej w celu minimalizacji strat ciepła i kosztów pompowania [14][15]. Optymalizacja pracy węzłów ciepła obejmuje zagadnienie odpowiedniego sterowania poziomem mocy cieplnej i temperaturami w obiegu grzewczym, na potrzeby efektywnego zarządzania zużyciem ciepła w budynkach [16]. W procesie optymalizacji pracy poszczególnych elementów systemu ciepłowniczego wykorzystywane są modele obliczeniowe, dzięki którym możliwa jest prognoza parametrów pracy i obliczenie istotnych wskaźników technicznych, dla zakładanych warunków eksploatacji. Do modelowania pracy źródeł ciepła i sieci ciepłowniczej mogą być stosowane metody oparte o modele fizyczne [17]. Metody te znalazły zastosowanie do problemu doboru układu technologicznego elektrociepłowni [18] i projektowaniu miejskich sieci ciepłowniczych [19]. W przypadku modelowania pracy istniejących obiektów na potrzeby prognozowania ich parametrów produkcyjnych, powszechnie stosowane są metody statystycznej analizy danych eksploatacyjnych, jak algorytmy uczenia maszynowego [20][21]. Zdaniem Bergsteinsson'a i in. [22], takie podejście umożliwia uwzględnienie wielu czynników wpływających na parametry pracy systemu ciepłowniczego w zmiennych i trudnych do przewidywania warunkach, przy jednoczesnym uproszczeniu procesu modelowania. Algorytmy analizy danych zostały skutecznie wdrożone w rzeczywistych systemach nadzoru pracy sieci ciepłowniczych i elektrociepłowni. Eguiarte i in. [23] wykazali, że zastosowanie modeli przewidujących specyfikę poboru ciepła przez odbiorców końcowych doprowadziło do zmniejszenia strat ciepła o ok. 5% w sieci ciepłowniczej miasta Tartu w Estonii. Touš i in. [24] wykorzystali metody uczenia maszynowego do opracowania modelu do symulacji pracy spalarni odpadów w Czechach pracującej w systemie ciepłowniczym. Optymalizacja produkcji ciepła i energii elektrycznej w elektrociepłowni może obejmować horyzont długoterminowy, średnioterminowy lub krótkoterminowy [25]. Celem procesu jest zaplanowanie pracy elektrociepłowni z uwzględnieniem maksymalizacji zysku operacyjnego dla wytwórcy, rozumianego jako różnica pomiędzy przychodami ze sprzedaży, a kosztem wytworzenia energii. W horyzoncie długoterminowym obejmującym okres do kilku lat do przodu, planowane są działania związane z nowymi inwestycjami i modernizacjami układów technologicznych, biorąc pod uwagę prognozowane profile zapotrzebowania na ciepło, stan sieci ciepłowniczej i uwarunkowania lokalnego rynku ciepła. Okres średnioterminowy obejmuje okres

roku kalendarzowego i ma na celu zaplanowanie strategii operacyjnej związanej ze sprzedażą produkowanego ciepła, energii elektrycznej i zakupem paliwa, w ramach kontraktów długoterminowym. Optymalizacja krótkoterminowa dotyczy bieżącej eksploatacji i obejmuje horyzont kilku następnych dni [26]. Przychód związany ze sprzedażą ciepła uwarunkowany jest od bieżącego poziomu zapotrzebowania na ciepło przez sieć ciepłowniczą. Z uwagi na regulowany rynek ciepła, wytworzone ciepło jest sprzedawane po stałej cenie, ustalonej w taryfie. Energia elektryczna zakontraktowana może być poprzez kontrakty bilateralne oraz transakcje typu SPOT na hurtowym rynku (na Rynku Dnia Następnego), które są deklarowane dla każdej godziny doby w dniu poprzedzającym realizację [27]. W tym przypadku, w dobie realizacji, wytwórca produkuje energię zgodnie z wcześniej zawartym kontraktem. W przypadku faktycznej realizacji produkcji w danej godzinie na innym niż zadeklarowanym poziomie, skutkuje to wystąpieniem odchylenia od kontraktu. W konsekwencji związane jest to z koniecznością zakupu bądź sprzedaży energii elektrycznej na Rynku Bilansującym [28], co może powodować obniżenie poziomu zysku.

Optymalne dobieranie profilu pracy jednostek wytwórczych zasilających miejską sieć ciepłowniczą musi być poprzedzone zaprognozowaniem zapotrzebowania na ciepło konieczne do oddania ze źródła do systemu ciepłowniczego. Dokładne przewidywanie godzinowego obciążenia cieplnego oraz prognoza parametrów produkcyjnych jednostek wytwórczych w zmiennych warunkach eksploatacyjnych (związanych z warunkami atmosferycznymi, specyfiką poboru ciepła przez sieć ciepłowniczą) stanowi złożone zadanie. Na godzinowe zapotrzebowanie na ciepło, poza danymi pogodowymi, wpływa charakter poboru ciepła przez użytkowników końcowych, a także dynamika sieci ciepłowniczej pod wpływem zmiennych warunków, takich jak bezwładność cieplna budynków, straty ciepła i inercja sieci w związku z częstymi zmianami strumieni i temperatur wody sieciowej [29][30]. Elektrociepłownia wyposażona w kilka jednostek wytwórczych kogeneracyjnych oraz akumulator ciepła, posiada duży potencjał do optymalizacji pracy. Na ten cel, konieczna jest analiza wielu czynników związanych z charakterystyką pracy jednostek wytwórczych oraz aspektem ich współpracy z siecią ciepłowniczą i sposobem regulacji dostaw ciepła. Podczas etapu krótkoterminowej optymalizacji pracy elektrociepłowni, poza spodziewanym profilem zapotrzebowania na ciepło, należy uwzględnić m.in. ceny energii elektrycznej i ciepła, koszty paliwa, uprawnień do emisji CO₂, potrzeby własne obiektu [31]. Kluczowe parametry pracy jednostek wytwórczych w zakładanym horyzoncie czasowym optymalizacji (ilość wytwarzanej energii elektrycznej, ilość produkowanego ciepła, zużycie paliwa, poziom emisji zanieczyszczeń) mogą być obliczane z wykorzystaniem metod modelowania termodynamicznego [32]. Jak wskazują Wan i in. [33], w celu uzyskania precyzyjnych obliczeń w zmiennych, poza projektowych warunkach eksploatacyjnych, należy kalibrować modele matematyczne w oparciu o rzeczywiste dane ruchowe. Problem ten ma szczególne znaczenie w przypadku turbin gazowych, których możliwości wytwórcze są silnie uzależnione od aktualnej temperatury czy wilgotności powietrza dolotowego. Dokładność prognozy zapotrzebowania na ciepło można zwiększyć poprzez zastosowanie algorytmów uczenia maszynowego, które pozwalają na analizę wielu danych klimatycznych, a także specyfiki zachowania odbiorców końcowych w różnych okresach eksploatacji

systemu ciepłowniczego (podczas sezonu grzewczego i poza nim) [34]. Wszystkie te przypadki należy jednak traktować osobno, z uwagi na indywidualne cechy zarówno źródła ciepła jak i sieci ciepłowniczej oraz zachowania lokalnych odbiorców powiązane z daną lokalizacją i strefą klimatyczną.

Podsumowując, optymalizacja krótkoterminowa (w horyzoncie nadchodzącej doby) elektrociepłowni gazowej polega kolejno na [25]:


- przewidzeniu godzinowego zapotrzebowania na ciepło, które będzie oddane przez źródło do sieci ciepłowniczej,
- doborze jednostek wytwórczych i ustaleniu ich charakteru pracy na przestrzeni analizowanej doby,
- obliczeniach produkcji energii elektrycznej desygnowanych do pracy jednostek,
- wyznaczeniu zapotrzebowania na paliwo gazowego,
- złożeniu odpowiednich dyspozycji na rynkach energii elektrycznej i gazu w celu optymalizacji sprzedaży i zakupu.

2.1 Stan zagadnienia w zakresie prognozowania zapotrzebowania na ciepło

Do prognozowania zapotrzebowania na ciepło w systemach ciepłowniczych (zarówno w skali indywidualnego budynku, obszarów bądź całej sieci ciepłowniczej) powszechnie stosowane są modele predykcyjne oparte o technikę uczenia maszynowego nadzorowanego (ang. supervised learning) [35]. Podejście to polega na zbudowaniu modelu do predykcji zmiennej, która podlega prognozowaniu w oparciu o zmienne objaśniające model (często z pominięciem równań fizycznych opisujących zjawisko). Jest to sposób uczenia, w którym zbiór danych, wykorzystywany do uczenia modelu, zawiera dołączone rozwiązanie problemu. Dwa główne zadania wykorzystujące uczenie nadzorowane to rozwiązywanie problemu regresji (przewidywanie wartości ciągłych) i problem klasyfikacji (przewidywanie klas zmiennej). Problem prognozowania godzinowej mocy cieplnej jest więc problemem regresyjnego uczenia nadzorowanego (gdzie model mocy cieplnej jest uczony m.in. na podstawie danych pogodowych). Na Rys. 2.1 przedstawiono podział wybranych algorytmów predykcyjnych, opartych o algorytmy uczenia maszynowego.

Najprostszym algorytmem regresyjnego uczenia nadzorowanego, jest algorytm regresji liniowej. Dotzdauer [36] wykorzystał tą metodę do prognozowania mocy cieplnej przy użyciu regresji liniowej temperatury otoczenia. Baltputnis i in. [37] zbudowali model wykorzystujący regresję wieloraką, uzupełnioną o korektę błędów w zależności od godziny doby. Metody autoregresji szeregów czasowych ARIMA mocy cieplnej i temperatury otoczenia zostały zastosowane przez Grosswindhager'a [38] oraz Fang'a [39]. Wojdyga [40] wykorzystał sztuczne sieci neuronowe ANN do uczenia modelu na danych z kilku historycznych sezonów grzewczych. Jako dane wejściowe do modelu ANN została przyjęta temperatura otoczenia oraz moc cieplna w poprzedzających godzinach i dniach. W ostatnich latach odnotować można wyraźny wzrost zainteresowania metodami uczenia maszynowego do prognozowania potrzeb cieplnych w sieci ciepłowniczej, takimi jak metoda wektorów skośnych (ang. Support Vector Machines) [41], lasu losowego (ang. Random Forest) [42], drzew decyzyjnych

(ang. Decision Trees) [43][44]. Wynika to między innymi z intensywnego rozwoju narzędzi informatycznych stosowanych w dużych instalacjach przemysłowych, pojemności baz danych oraz dostępności systemów akwizycji danych. Techniki uczenia maszynowego pozwalają na znajdowanie zależności wpływających na moc ciepłą, poprzez uwzględnienie wielu zmiennych poza danymi klimatycznymi, jak dane procesowe z sieci ciepłowniczej czy dane kalendarzowe (dzień tygodnia, miesiąc, okresy świąteczne). Takie podejście zostało zaproponowane w pracy Saloux i in. [45], którzy wykazali że uwzględnienie zmiennych w postaci godziny doby i dnia tygodnia poprawia dokładność prognozowania zapotrzebowania na ciepło w horyzoncie doby następnej. W literaturze znaleźć można aplikacje algorytmów prognostycznych, na potrzeby optymalizacji pracy rzeczywistych systemów ciepłowniczych. Kurek i in. [46] opracowali system prognozowania zapotrzebowania na ciepło w warszawskiej sieci ciepłowniczej. Zastosowali algorytmy regresji grzbietowej i głębokiej sztucznej sieci neuronowej. Petrichenko i in. [47] badali zastosowanie sieci neuronowych do prognoz zapotrzebowania na ciepło w sieci ciepłowniczej w Rydze.



Rys. 2.1. Podział wybranych algorytmów uczenia nadzorowanego dla zadania regresji

Jak wskazują Chen i in. [48] modele uczenia maszynowego ze skomplikowanymi algorytmami sieci neuronowych, drzew decyzyjnych są modelami typu czarnej skrzynki (ang. black-box) i mogą być bardzo trudne w interpretacji i rozumieniu wpływu poszczególnych zmiennych objaśniających model na zmienną prognozowaną. Z drugiej strony, proste do implementacji i łatwe w interpretacji modele oparte o regresję liniową, wielomianową z jedną zmienną objaśniającą, mogą nie oddać złożoności natury badanego zjawiska i okazać się niewystarczająco dokładne. Jednym z algorytmów regresyjnego uczenia nadzorowanego jest algorytm Uogólnionego Modelu Addytywnego GAM (ang. Generalized Additive Model). Algorytm GAM pozwala na uwzględnienie wielu zmiennych na etapie uczenia modelu i jest stosunkowo łatwy w interpretacji i zrozumieniu, w jaki sposób każdy z predyktorów wpływa na wynik.

Kamma i in. [49] wykorzystali algorytm GAM do opracowania modelu do predykcji zapotrzebowania na ciepło dla budynku biurowego. Jak wskazują, algorytm GAM pozwala na uwzględnienie wpływu zmiennych objaśniających zmienną prognozowaną w sposób umożliwiający interpretację. W literaturze problemu prognozowania zapotrzebowania na ciepło w skali wielkomiejskich sieci ciepłowniczych, algorytm GAM nie jest popularny. Jedyną znaną autorowi rozprawy jest praca Bianchi'ego i in. [50], którzy zastosowali metodę GAM do budowy modelu zapotrzebowania na ciepło w okresie grzewczym dla sieci ciepłowniczej we włoskiej Weronie. Opracowany model oprócz danych pogodowych uwzględnia także zmienną kalendarzową, jak dzień tygodnia.

Z punktu widzenia planowania pracy elektrociepłowni i uwarunkowań ze zgłaszaniem planowanej produkcji energii elektrycznej w nadchodzącej dobie, model predykcyjny powinien wykazywać wysoką dokładność w horyzoncie doby następnej [51]. Proces planowania i optymalizacji krótkoterminowej elektrociepłowni dotyczy pełnego roku kalendarzowego, w związku z tym pożądanym jest, aby model był w stanie prognozować zapotrzebowanie na ciepło w sieci ciepłowniczej poza sezonem grzewczym [52]. Należy nadmienić, że zdecydowana większość proponowanych rozwiązań w literaturze przedmiotu dotyczy wyłącznie okresu grzewczego.

Podczas budowy i wdrażania modelu prognostycznego w systemie ciepłowniczym, należy mieć na uwadze, że modele, które dobrze dopasowują się do uczącego zbioru danych, mogą wykazywać niską dokładność na nowym zbiorze danych. Jest to zjawisko określane „przetrenowaniem” modelu. Ponadto, uczenie modelu na dużym zbiorze pozwala znaleźć skomplikowane zależności między danymi w relacji do zmiennej prognozowanej, jednakże profil zapotrzebowania może się szybko zmieniać, poprzez zmianę nawyków odbiorców ciepła, termomodernizację budynków, zmianę regulacji nastaw parametrów wody sieciowej, czy nowe przyłączenia do sieci ciepłowniczej. Z tego powodu dużą uwagę przywiązuje się do metod kalibracji, w celu bieżącego uczenia modelu do aktualnej specyfiki eksploatacji systemu [53][54]. Problem ten dotyczy sposobu uczenia, w tym odpowiedniego strojenia parametrów obliczeniowych oraz odpowiedniego doboru rozmiaru i okresu czasowego z danymi treningowymi.

2.2 Stan zagadnienia w zakresie prognozowania parametrów produkcyjnych turbiny gazowej

Do analizy koncepcyjnej i projektowania układu z turbinami gazowymi najczęściej stosuje się modelowanie termodynamiczne. Podobnie, w trakcie eksploatacji jednostek, modele oparte o równania fizyczne, są wykorzystywane do diagnozowania, sterowania i zarządzania procesem produkcyjnym [55]. Jednym z zastosowań modelowania jest krótkoterminowe planowanie produkcji w elektrociepłowni. W tym zastosowaniu, model służy do symulacji pracy jednostek produkcyjnych w warunkach poza projektowych (ang. off-design) dla horyzontu dnia następnego [56]. Żymełka i in. [57] zamodelowali elektrociepłownię gazową w celu optymalizacji współpracy turbin gazowych z akumulatorem ciepła z wykorzystaniem komercyjnego oprogramowania Epsilon Professional. Aminow i in. [58] przedstawili

metodę wyznaczania całkowitych kosztów eksploatacji z uwzględnieniem postępującej degradacji turbiny gazowej. Madejski i in. [59] przedstawili koncepcję narzędzia do monitorowania i optymalizacji produkcji ciepła i energii elektrycznej w elektrociepłowni współpracującej z miejską siecią ciepłowniczą. Problem minimalizacji emisji CO₂ w oparciu o modelowanie termodynamiczne w elektrowni gazowo-parowej, uwzględniający zarówno obciążenia elektryczne, jak i cieplne, rozważali Rigo-Mariani i in. [60].

Mohamed i in. [61] wyróżnili trzy podejścia w modelowaniu pracy turbin gazowych. Pierwszym z nich jest modelowanie oparte o równania fizyczne, które zapewnia interpretację procesu w postaci równań matematycznych opisujących zachowanie systemu. Istnieje wiele komercyjnych programów do modelowania procesów termodynamicznych w oparciu o równania bilansu masowego i cieplnego. Programy te wyposażone są w komponenty odzwierciedlające modele fizyczne maszyn i urządzeń wchodzących w skład typowych układów technologicznych wytwarzania energii. Kowalczyk i in. [62] wykorzystali to podejście do modelowania rzeczywistej elektrociepłowni z wymiennikami ciepłowniczymi zasilanymi spalinami z turbin gazowych.

Drugim podejściem jest modelowanie empiryczne (modele typu „black-box”) [63]. Modele czarnej skrzynki zastępują modele fizyczne i są budowane na podstawie rzeczywistych danych ruchowych z eksploatacji obiektu. Algorytmy uczenia maszynowego (m.in. sztuczne sieci neuronowe ANN) zostały zaadaptowane do wielu rozwiązań problemów dotyczących monitorowania, prognozowania, diagnozowania uszkodzeń i sterowania turbinami gazowymi [64][65][66]. Modele zasilane danymi, są również wykorzystywane do przewidywania wydajności turbin gazowych i parametrów produkcyjnych, takich jak wytwarzanie energii elektrycznej i ciepła, zużycie paliwa w horyzoncie kilku następnych godzin, jak i nadchodzącej doby [67][68].

Trzecie podejście to metoda kombinowana, polegająca na łączeniu modelu termodynamicznego oraz korelacji empirycznych, w tym krzywych charakterystycznych dla danego urządzenia dostarczanych przez producenta [69]. Zgodnie z tą koncepcją, szczegółowy model fizyczny elementów turbiny gazowej (sprężarka, komora spalania, turbina) zostaje zastąpiony krzywymi korekcyjnymi podanymi przez producenta danej jednostki [70]. Krzywe korekcji można wykorzystać do przewidywania wydajności przy pełnym lub częściowym obciążeniu w dowolnych warunkach pracy, w tym dla warunków poza projektowych – off-design [71]. Charakterystyka turbiny gazowej oparta jest na danych wejściowych, takich jak parametry termofizyczne powietrza na wlocie do sprężarki oraz otoczenia [72]. Jednak krzywe korekcyjne mogą nie być wystarczająco dokładne w przewidywaniu nietypowego zachowania turbiny gazowej. Ze względu na stopniową degradację jednostki mogą wystąpić rozbieżności pomiędzy danymi producenta, a rzeczywistymi osiąganymi turbiną. Uzyskanie wiarygodnych wyników jednostki, która uległa częściowej degradacji jest możliwe poprzez zastosowanie złożonych modeli numerycznych (w szczególności komputerowej mechaniki płynów CFD). Obliczenia tak złożonych procesów są bardzo czasochłonne i wymagają bardzo szczegółowych doprecyzowanych do aktualnych warunków modeli numerycznych. W celu utrzymania

wysokiej wiarygodności wyników maszyn i urządzeń, które zużywają się w trakcie eksploatacji konieczne jest zastosowanie metod uproszczonych. Aby przezwyciężyć ten problem, Liu i in. [73] oraz Carvahlo i in. [74] zaproponowali metodę korekcji krzywych korekcyjnych turbiny gazowej, na podstawie analizy rzeczywistych danych eksploatacyjnych. Podobne podejście zaproponowali Szega i in. [75], wprowadzając współczynniki poprawkowe dla modelu krzywych korekcyjnych turbiny gazowej od producenta, wraz z algorytmami detekcji stanów ustalonych pracy jednostki.

2.3 Stan zagadnienia w zakresie optymalizacji produkcji w dobie następnej

Nowe rozwiązania i narzędzia dla optymalizacji wytwarzania energii elektrycznej i ciepła dla układów pracujących w obrębie systemu ciepłowniczego, uwzględniające aspekty ekonomiczne i środowiskowe są w ciągłym rozwoju. Obecnie, następuje postępujący rozwój cyfryzacji, a stosowanie zaawansowanych metod analizy danych jest trendem w najnowszych generacji systemów ciepłowniczych [76]. W literaturze można znaleźć wiele przykładów takich jak np. praca Fang i in. [77], którzy zaproponowali model optymalizacji pracy akumulatora ciepła, gdzie prognozowane jest zapotrzebowanie na ciepło i ceny energii elektrycznej. Wand i in. [78] podjęli się zbadania elastycznej pracy dwóch jednostek kogeneracyjnych, biorąc pod uwagę uwarunkowania rynku dnia następnego wraz z bilansowaniem sieci elektroenergetycznej energią elektryczną z turbin wiatrowych w czasie rzeczywistym. Mordasiewicz i in. [79] przeanalizowali możliwość wypracowania dodatkowych zysków na rynku energii elektrycznej dla współpracujących z siecią ciepłowniczą silników gazowych.

W analizowanym w rozprawie doktorskiej przypadku pracy elektrociepłowni gazowej, zagadnienie optymalizacyjne związane jest z opracowaniem funkcji celu, która zawiera człon odpowiedzialny za strumień przychodów ze sprzedaży energii elektrycznej, ciepła oraz kosztów zakupu paliwa gazowego i uprawnień do emisji CO₂. Metody stosowane na potrzeby optymalizacji pracy systemów ciepłowniczych zostały sklasyfikowane przez Sarbu i in. [80] na metody deterministyczne oraz heurystyczne. Deterministyczne techniki optymalizacji to klasa matematycznych metod stosowanych do znalezienia najlepszego rozwiązania danego problemu, gdy parametry i ograniczenia są znane i nie obejmują żadnego elementu losowości lub niepewności. Poniżej przedstawiono wybrane techniki metod deterministycznych stosowane na potrzeby optymalizacji pracy elektrociepłowni.

- Programowanie liniowe LP (ang. Linear Programming): to metoda do optymalizacji liniowej funkcji celu podlegającej liniowym ograniczeniom. Ta metoda znalazła zastosowanie w pracy Abdollahi i in. [81], której autorzy opracowali z model do minimalizacji kosztów wytwarzania energii w elektrociepłowni z silnikami gazowymi współpracującymi z magazynem ciepła, przy uwzględnieniu przychodów ze sprzedaży energii elektrycznej.
- Programowanie liniowe całkowitoliczbowe MILP (ang. Mixed Integer Linear Programming): łączy programowanie liniowe i całkowitoliczbowe, pozwalając

niektórym zmiennym przyjmować wartości ciągłe, a inne ograniczać do liczb całkowitych. Turunen i in. [82] zastosowali metodę MILP do planowania pracy akumulatora ciepła w elektrociepłowni na potrzeby maksymalizacji przychodów z rynku energii elektrycznej.

- Programowanie nieliniowe NLP (ang. Nonlinear Programming): zajmuje się problemami optymalizacyjnymi, w których funkcja celu lub ograniczenia zawierają nieliniowe równania. Kim i in. [83] opracowali model optymalizacji pracy układu gazowo-parowego na potrzeby planowania pracy w dobie następnej, z uwzględnieniem nieliniowej funkcji celu do maksymalizacji przychodów operacyjnych.

Metody heurystycznej optymalizacji służą do znalezienia przybliżonych rozwiązań dla złożonych problemów optymalizacyjnych. Metody te stosowane są, gdy znalezienie dokładnego rozwiązania w rozsądnym czasie jest niemożliwe. Sarbu i in. [80] wyróżnili następujące algorytmy należące do rodziny algorytmów heurystycznych.

- Algorytmy genetyczne: są inspirowane procesem selekcji naturalnej. Wykorzystują mechanizmy takie jak selekcja, krzyżowanie i mutacja do ewoluowania populacji potencjalnych rozwiązań. Są często stosowane w problemach optymalizacji o dużej przestrzeni rozwiązań. Algorytmy genetyczne zostały wykorzystane na potrzeby wyznaczenia optymalnej strategii pracy akumulatora ciepła w elektrociepłowni przez Wanga i in. [84]. Zidan i in. [85] zastosowali algorytm genetyczny do minimalizacji emisji CO₂.
- Algorytmy ewolucyjne: Żymelka i in. [86] zastosował algorytm ewolucyjny do krótkoterminowego planowania pracy elektrociepłowni opalanej gazem ziemnym, przy uwzględnieniu maksymalizacji zysku operacyjnego.
- Optymalizacja rojem cząstek: Xiong i in. [88] zastosowali tą technikę do optymalizacji opłat za emisję CO₂, podczas bieżącej pracy elektrociepłowni.


3 Cel, teza oraz zakres pracy

Proces decyzyjny dotyczący planowania produkcji ciepła i energii elektrycznej w elektrociepłowni dla horyzontu następnej doby, jest związany z koniecznością analizy dużej ilości danych pogodowych i procesowych. Zmienne te charakteryzują się specyficznymi cechami, takimi jak sezonowość oraz częsty i trudny do przewidzenia poziom fluktuacji. Opracowanie algorytmów bazujących na analizie danych wraz z budową odpowiednich narzędzi wsparcia podejmowania decyzji, może potencjalnie pozwolić na znaczącą poprawę efektywności procesów produkcyjnych i ich optymalizację.

Celem niniejszej pracy jest opracowanie narzędzia do krótkoterminowego planowania i optymalizacji pracy rzeczywistej elektrociepłowni w Toruniu, składającej się z dwóch kogeneracyjnych turbin gazowych z odzyskiem ciepła w wodnych kotłach odzyskowych, akumulatora ciepła i kotłów gazowo-olejowych. Narzędzie wraz z algorytmami do prognozy zapotrzebowania na ciepło oraz symulacji pracy jednostek wytwórczych, ma umożliwić przeprowadzenie optymalizacji produkcji w ciągu pełnego roku kalendarzowego. Modele predykcyjne w swojej funkcjonalności mają posiadać mechanizmy do kalibracji w celu bieżącego dostosowywania się do specyfiki poboru ciepła przez sieć ciepłowniczą oraz uwzględniać aktualne zdolności wytwórcze źródeł ciepła, dla zmiennych warunków eksploatacji elektrociepłowni. Osiągnięcie celu pracy wymagało realizacji poszczególnych zagadnień badawczych:

- Opracowanie modelu dla predykcji godzinowego zapotrzebowania na ciepło, wraz z selekcją danych wejściowych i strojeniem parametrów algorytmu, w celu uzyskania wysokiej dokładności w dobie następnej. Wypracowanie metody adaptacji modelu do aktualnej specyfiki poboru ciepła w sieci ciepłowniczej dla wskazanej lokalizacji i trwającego aktualnie sezonu.
- Opracowanie modelu do symulacji pracy układu turbiny gazowej z odzyskiem ciepła w wodnym kotle odzysknicowym, na potrzeby analizy stanów pracy w zakładanych warunkach eksploatacyjnych i dla zadanego zapotrzebowania na ciepło. Opracowanie metody kalibracji modelu w oparciu o dane ruchowe, prowadzącej do poprawy prognoz parametrów produkcyjnych w horyzoncie planowania produkcji.
- Opracowanie warstwy optymalizatora, umożliwiającej zaplanowanie pracy elektrociepłowni w horyzoncie doby następnej, dla zdefiniowanej funkcji celu określającej umowny zysk operacyjny elektrociepłowni.
- Przetestowanie opracowanych modeli oraz weryfikacja uzyskanych wyników, poprzez porównanie wartości z modeli prognostycznych narzędzia z rzeczywistymi parametrami mierzonymi w elektrociepłowni.

Na Rys. 3.1 przedstawiono schemat ideowy narzędzia uwzględniający zagadnienia omówione powyżej. Zestawy danych o stanie pracy sieci ciepłowniczej, danych pogodowych i danych procesowych z eksploatacji jednostek wytwórczych zasilają moduły prognozowania zapotrzebowania na ciepło oraz model termodynamiczny. Wyniki z modeli są daną wsadową do optymalizatora produkcji, generującego wynik w postaci scenariusza produkcji dla horyzontu doby następnej.



Rys. 3.1 Koncepcja narzędzia do planowania pracy elektrociepłowni, w oparciu o model zapotrzebowania na ciepło i model termodynamiczny jednostki wytwórczej.

Prowadzone w ramach pracy doktorskiej badania pozwolą zweryfikować następujące hipotezy badawcze:

- Zastosowanie metod uczenia maszynowego pozwala na zwiększenie dokładności godzinowych prognoz zapotrzebowania na ciepło w horyzoncie doby następnej w badanym systemie ciepłowniczym. Poprawa dokładności godzinowych prognoz zapotrzebowania na ciepło jest możliwa przy zastosowaniu co najmniej dwóch predyktorów, w tym godziny danej doby.
- Kalibracja wyników modelu termodynamicznego turbiny gazowej, na podstawie metod analizy rzeczywistych danych ruchowych, umożliwia zwiększenie dokładności prognoz parametrów produkcyjnych w horyzoncie doby następnej.
- Opracowane narzędzie do planowania produkcji oparte o model zapotrzebowania na ciepło i model termodynamiczny jednostki wytwórczej umożliwia przeprowadzenie krótkoterminowej optymalizacji pracy elektrociepłowni dla wybranej funkcji celu, poprzez uzyskiwanie dokładnych prognoz parametrów produkcyjnych.

Podsumowując zaproponowany zakres oraz zagadnienia, jako główny cel rozprawy doktorskiej należy wskazać opracowanie narzędzia do krótkoterminowego planowania i optymalizacji pracy badanej elektrociepłowni, z zastosowaniem metod uczenia maszynowego i modelowania termodynamicznego. Celem użytecznym jest praktyczne zastosowanie opracowanych modeli progностycznych i ich wdrożenie w rzeczywistej elektrociepłowni w postaci narzędzia stanowiącego system wsparcia służb odpowiedzialnych za proces planowania i optymalizacji krótkoterminowej. Jest to możliwe poprzez osiągnięcie wysokiej dokładności modeli prognozowania i jednostek wytwórczych dla zakładanego horyzontu optymalizacji (doby następnej).

Jako drugi cel użyteczny należy wskazać poprawę dokładności w prognozowaniu zapotrzebowania na ciepło w horyzoncie doby następnej, w porównaniu do obecnie stosowanych metod bazujących wyłącznie na wykorzystaniu jednej zmiennej - temperatury otoczenia w skali miasta. Poprawa dokładności prognozowania zapotrzebowania na ciepło przyczynia się do poprawy dokładności w prognozowaniu generowanej energii elektrycznej, zużycia paliwa gazowego oraz emisji szkodliwych substancji do środowiska, w szczególności emisji gazu cieplarnianego CO₂, co umożliwi potencjalne osiągnięcie efektów ekonomicznych podczas eksploatacji badanego obiektu.

4 Opis obiektu badań


Przedstawione w niniejszej rozprawie narzędzie zostało opracowane i wdrożone dla spółki PGE Toruń S.A., należącej do PGE Energia Ciepła S.A. Spółka jest właścicielem elektrociepłowni gazowej (EC) i miejskiej sieci ciepłowniczej (MSC) w Toruniu. W skład badanego układu wchodzi elektrociepłownia z dwoma kogeneracyjnymi turbinami gazowymi z odzyskiem ciepła w wodnych kotłach odzysknicowych, czterema kotłami rezerwowo-szczytowymi oraz akumulatorem ciepła [89]. Zainstalowana moc elektryczna elektrociepłowni wynosi 107,1 MWe, a moc cieplna 357,6 MWt. Całkowita długość MSC przekracza 260 km, a sieć zasilą około 2500 budynków. Sieć jest nieustannie rozwijana i modernizowana. Tylko w 2023r. do sieci przyłączono przyłączone zostały 53 budynki, o łącznym zapotrzebowaniu na ciepło na poziomie 7,5 MWt. Sieć ciepłownicza oprócz elektrociepłowni gazowej produkującej ok. 91% ciepła w ciągu roku kalendarzowego, zasilana jest również z ciepłowni geotermalnej oraz biogazowni. Udział ciepła w rocznej produkcji z geotermii stanowi obecnie ok. 8%, a udział ciepła z ciepłowni biogazowej poniżej 1%.

Miasto Toruń przedzielone jest naturalnie rzeką Wisłą na część prawobrzeżną i lewobrzeżną. Sieć ciepłownicza obejmuje prawobrzeżną część miasta. W lewobrzeżnej części miasta, ze względu na uwarunkowania geograficzne i związane z tym trudności techniczne i ekonomiczne nie ma zorganizowanego systemu ciepłowniczego. Ta część miasta zaopatrywana jest w ciepło z indywidualnych źródeł ciepła oraz z kotłowni lokalnych należących do PGE Toruń (8 gazowych i 2 olejowe, o łącznej mocy ok. 2,5 MWt).

4.1 Sieć ciepłownicza

Znajdująca się w Toruniu sieć ciepłownicza ma długość równą 265 km, a jej pojemność to 25 474 m³. Kształt geometryczny sieci jest pierścieniowo-promienisty. Sieć ciepłownicza jest stale modernizowana w celu zastąpienia tradycyjnych rurociągów kanałowych na preizolowane, które zapewniają niższe straty ciepła. Obecnie stopień preizolacji sieci to ok. 63% (151,3 km). Schemat rurociągów sieci ciepłowniczej wraz z będącym obiektem badań źródłem ciepła (elektrociepłownią gazową) przedstawia Rys. 4.1. W ciągu roku kalendarzowego MSC z badanej elektrociepłowni jest zasilana wodą sieciową o strumieniu masowym zmieniającym się w zakresie od ok. 700 do 3500 t/h. Tab. 4.1 przedstawia parametry temperaturowe sieci ciepłowniczej w zależności od warunków pogodowych (temperatura otoczenia, nasłonecznienie, prędkość wiatru). Wraz ze zmieniającymi się warunkami atmosferycznymi, temperatura wody zasilającej sieć ciepłowniczą przez źródło jest wyznaczana na podstawie zaprezentowanej tabeli regulacyjnej. W aktualnym stanie, strumień przepływu wody sieciowej jest dobierany tak, aby pokryć bieżące zapotrzebowanie na ciepło przy zachowaniu wymaganego poziomu temperatur wody

sieciowej wynikający z tabeli regulacyjnej. Prezentowany sposób pokrycia zapotrzebowania przez sieć ciepłowniczą to przykład regulacji ilościowo-jakościowej [90]. Tabela regulacyjna jest ustalana każdorazowo przed rozpoczęciem sezonu grzewczego i zawiera wymagane parametry temperaturowe, które w danych warunkach umożliwią dostawy ciepła do wszystkich odbiorców ciepła sieciowego na wymaganym poziomie jakościowym, przy uwzględnieniu problematyki minimalizacji strat ciepła w sieci i kosztów pompowania wody sieciowej.




Rys. 4.1. Mapa sieci ciepłowniczej w Toruniu z zaznaczonymi źródłami ciepła

Tab. 4.1. Tabela regulacyjna dla miasta Toruń przedstawiająca wartość współczynnika f_{ix} w zależności od temperatury otoczenia, trójstopniowej skali zachmurzenia oraz prędkości wiatru

Temp. otoczenia , °C	POCHMURNO			ZACHMURZENIE ZMIENNE			SŁONECZNIE		
	Prędkość wiatru do 3 m/s	Prędkość wiatru 3-8 m/s	Prędkość wiatru 8 m/s	Prędkość wiatru do 3 m/s	Prędkość wiatru 3-8 m/s	Prędkość wiatru 8 m/s	Prędkość wiatru do 3 m/s	Prędkość wiatru 3-8 m/s	Prędkość wiatru 8 m/s
-20	1,00	1,04	1,07	0,99	1,03	1,06	0,98	1,02	1,05
-19	0,97	1,01	1,04	0,96	1,00	1,03	0,95	0,99	1,02
-18	0,95	0,99	1,02	0,94	0,97	1,00	0,92	0,96	0,99
-17	0,92	0,96	0,99	0,91	0,95	0,98	0,90	0,93	0,96
-16	0,90	0,94	0,96	0,88	0,92	0,95	0,87	0,90	0,93
-15	0,88	0,91	0,94	0,86	0,89	0,92	0,84	0,88	0,90
-14	0,85	0,88	0,91	0,83	0,87	0,89	0,81	0,85	0,87
-13	0,82	0,86	0,88	0,81	0,84	0,86	0,79	0,82	0,84
-12	0,80	0,83	0,86	0,78	0,81	0,83	0,76	0,79	0,81
-11	0,77	0,81	0,83	0,75	0,78	0,81	0,73	0,76	0,78
-10	0,75	0,78	0,80	0,73	0,76	0,78	0,70	0,73	0,75
-9	0,72	0,75	0,76	0,70	0,73	0,75	0,68	0,70	0,72

-8	0,70	0,73	0,75	0,67	0,70	0,72	0,65	0,68	0,70
-7	0,67	0,70	0,72	0,65	0,67	0,69	0,62	0,65	0,67
-6	0,65	0,68	0,70	0,62	0,65	0,67	0,59	0,62	0,64
-5	0,63	0,65	0,67	0,60	0,62	0,64	0,57	0,59	0,61
-4	0,60	0,62	0,64	0,57	0,59	0,61	0,54	0,56	0,58
-3	0,57	0,60	0,62	0,54	0,57	0,58	0,51	0,53	0,55
-2	0,55	0,57	0,59	0,52	0,54	0,55	0,48	0,50	0,52
-1	0,52	0,55	0,56	0,49	0,51	0,53	0,46	0,48	0,49
0	0,50	0,52	0,53	0,47	0,48	0,50	0,43	0,45	0,46
1	0,47	0,49	0,51	0,44	0,46	0,47	0,40	0,42	0,43
2	0,45	0,47	0,48	0,41	0,43	0,44	0,37	0,39	0,40
3	0,42	0,44	0,45	0,39	0,40	0,41	0,35	0,36	0,37
4	0,40	0,42	0,43	0,36	0,37	0,39	0,32	0,33	0,34
5	0,38	0,39	0,40	0,33	0,35	0,36	0,29	0,30	0,31
6	0,35	0,36	0,37	0,31	0,32	0,33	0,26	0,28	0,28
7	0,32	0,34	0,35	0,28	0,29	0,30	0,24	0,25	0,25
8	0,30	0,31	0,32	0,25	0,27	0,27	0,21	0,22	0,22
9	0,27	0,29	0,29	0,23	0,24	0,24	0,18	0,19	0,20
10	0,25	0,26	0,27	0,20	0,21	0,22	0,15	0,16	0,17
11	0,22	0,23	0,24	0,18	0,18	0,19	0,13	0,13	0,14
12	0,20	0,21	0,21	0,15	0,16	0,16	0,10	0,10	0,11

Przedstawione w Tab. 4.1 dane pozwalają na wyznaczenie współczynnika f_{ix} , który zmienia się od 0,1 do 1,05. Współczynnik jest uzależniony od temperatury otoczenia, trójstopniowej skali zachmurzenia oraz prędkości wiatru. Temperatura wody sieciowej na zasilaniu i pożądana temperatura na powrocie jest wyznaczana na podstawie współczynnika f_{ix} , zgodnie z wykresem regulacyjnym przedstawionym na Rys. 4.2. Maksymalna temperatura na zasilaniu sieci ciepłowniczej wynosi 132 °C.



Rys. 4.2. Zależność temperatury zasilania T_z i powrotu T_p od współczynnika f_{ix}

Chwilowa moc cieplna $\dot{Q}$ przekazywana do sieci ciepłowniczej z elektrociepłowni zależy od natężenia przepływu wody sieciowej oraz różnicy temperatur między stroną zasilania i powrotu, zgodnie z równaniem (4.1). Temperatura wody sieciowej na wyprowadzeniu do miasta jest regulowana poprzez mieszanie zimnej wody sieciowej (woda powrotna z miasta), z wodą grzewczą za kolektorem zasilającym.

$$\dot{Q} = \dot{m}c_p(T_z - T_p) \quad (4.1)$$


gdzie:

$\dot{m}$ – przepływ masowy wody sieciowej na zasilaniu MSC, kg/s

c_p – średnie ciepło właściwe wody, kJ/(kg·K)

T_z – temperatura zasilania MSC, K

T_p – temperatura powrotu MSC, K



Rys. 4.3. Struktura odbiorców ciepła z uwzględnieniem liczby węzłów cieplnych i ich mocy cieplnej na potrzeby centralnego ogrzewania, ciepłej wody użytkowej, wentylacji.

Obciążenie cieplne analizowanego systemu ciepłowniczego determinowane jest przez zużycie ciepła przez użytkowników końcowych. Istnieje wiele typów użytkowników końcowych, którzy są zaopatrywani przez ciepło systemowe w Toruniu. Na Rys. 4.3 przedstawiono zainstalowaną moc cieplną wszystkich węzłów ciepłowniczych w podziale na rodzaj odbiorców końcowych. Największą grupę stanowi budownictwo mieszkaniowe, w tym domy jedno- i wielorodzinne wolnostojące i duże budynki wielomieszkaniowe, których udział w ogólnej liczbie węzłów cieplnych wynosi 67%. Udział węzłów cieplnych w budynkach takich jak hotele i obiekty usługowe, wynosi

14%. Pozostałymi rodzajami użytkowników końcowych są szkoły, służby zdrowia, administracja publiczna, instytucje religijne i budynki przemysłowe. Łączna moc zamówiona przez wszystkich odbiorców zasilanych za pośrednictwem sieci ciepłowniczej, zgodnie ze stanem na rok 2022, wyniosła 364,37 MW_t. Wśród wszystkich odbiorców ciepła sieciowego są trzy główne grupy:

- odbiorcy ciepła tylko na cele CO (Centralnego Ogrzewania),
- odbiorcy ciepła na cele CO oraz CWU (Ciepłej Wody Użytkowej),
- odbiorcy ciepła na cele CO, CWU oraz na cele WENT (Wentylacji).


Zdecydowana większość węzłów jest węzłami dwu- lub trzyfunkcyjnymi. Poza centralnym ogrzewaniem (CO) dostarczają ciepło do podgrzania ciepłej wody użytkowej (CWU) oraz do innych technologicznych celów, takich jak wentylacja (WENT), chłodzenie (KLIM). Poza sezonem grzewczym ciepło sieciowe dostarczane jest głównie na potrzeby CWU. Moc zainstalowana węzłów ciepłych dla CWU wynosi 55 MW i 17 MW, odpowiednio dla budownictwa mieszkaniowego i innych typów odbiorców końcowych. Poniżej, w Tab. 4.2 przedstawiono wykaz mocy zainstalowanej dla poszczególnych węzłów wraz z udziałem w łącznej mocy cieplnej zamówionej w EC dla magistrali zasilającej Toruń.

Tab. 4.2 Udział poszczególnych rodzajów węzłów ciepła


Rodzaj węzła ciepła	Moc węzłów, MW	Moc węzłów, %
CO	41,63	11,43%
CO+CWU	273,06	74,94%
CO+CWU+WENT	25,49	7,00%
CO+WENT	10,68	2,93%
CO+CWU+WENT+TECH	1,02	0,28%
CO+CWU+TECH	1,30	0,36%
CWU	0,03	0,01%
CWU+WENT	0,23	0,06%
WENT	9,41	2,58%
WENT+TECH	0,71	0,19%
KLIM	0,11	0,03%
TECH	0,71	0,19%
Łącznie	364,37	100,00%

Odbiorcy ciepła sieciowego z sektora budownictwa mieszkaniowego mają największy wpływ na poziom zapotrzebowania na ciepło oraz jego zmienność w czasie podczas eksploatacji systemu ciepłowniczego na przestrzeni pełnego roku kalendarzowego. Determinuje to konieczność dostosowywania specyfiki produkcji ciepła w źródle w zakresie bieżącej mocy wraz z parametrami temperaturowymi wody sieciowej, w poszczególnych godzinach doby, w celu zapewnienia wymaganych właściwości nośnika ciepła w miejscu jego rozbioru [91]. Podczas pracy elektrociepłowni i sterowania poziomem dostarczania energii cieplnej na zasilaniu miejskiej sieci

ciepłowniczej, należy uwzględnić oprócz kwestii związanych z czasem transportu czynnika roboczego do węzła ciepła [92], także problem inercji cieplnej poszczególnego budynku pod wpływem zmian danych pogodowych podczas okresu grzewczego [93]. Poza dostarczeniem ciepła na potrzeby ogrzewania budynków, należy uwzględnić profil zapotrzebowania na ciepłą wodę użytkową, który zakłada, że największe poziomy rozbiór ciepła występują w okresach porannych i wieczornych.



Rys. 4.4. Parametry wody sieciowej w wybranym okresie sezonu grzewczego



Rys. 4.5. Parametry wody sieciowej w wybranym okresie sezonu letniego

Sterowanie mocą elektrociepłowni realizowane jest przez operatora produkcji, jako odpowiedź na aktualny wymóg sieci ciepłowniczej. Do głównych zadań prawidłowego i skutecznego prognozowania zapotrzebowania na ciepło można więc zaliczyć prognozowanie temperatury wody sieciowej na zasilaniu oraz prognozowanie mocy cieplnej (wartość wynikająca z różnicy temperatur i strumienia wody sieciowej). Na powyższych rysunkach przedstawiono przebiegi czasowe parametrów wody sieciowej, obejmujące okres dwóch wybranych dni z okresu grzewczego (Rys. 4.4) oraz letniego (Rys. 4.5). Podczas okresu grzewczego, temperatura na zasilaniu jest utrzymywana zgodnie z tabelą regulacyjną w zależności od aktualnych danych atmosferycznych. Pompy wody sieciowej utrzymują wymagane ciśnienie dyspozycyjne na zasilaniu MSC. Poza sezonem grzewczym, woda sieciowa na zasilaniu MSC jest utrzymywana na stałych parametrach temperaturowych ok. 70/45 °C, a przepływ jest dostosowywany pod kątem uzyskania odpowiedniej mocy na zasilaniu miasta. Obecność w sieci zautomatyzowanych węzłów ciepła, które dostosowują się do chwilowego zapotrzebowania na ciepło w budynkach powodują, że w systemie ciepłowniczym praktycznie nie występują stabilne okresy pracy, a rzeczywiste parametry wody sieciowej mogą odbiegać od wielkości wynikających z wykresów regulacyjnych. W źródle ciepła należy uwzględniać te zakłócenia, tak by zapewnić wymagane warunki zasilania u wszystkich odbiorców. Z uwagi na duże opóźnienia pomiędzy zmianą chwilowej mocy cieplnej w źródle pracującym na sieć, a odpowiedzią obiektu (temperatura wody powrotnej do źródła) trudno jest dobrać optymalne parametry, biorąc pod uwagę zmienność warunków atmosferycznych.

4.2 Elektrociepłownia gazowa

Układ technologiczny badanej elektrociepłowni jest oparty o dwie pracujące w podstawie kogeneracyjne turbiny gazowe, które zasilają spalinami wodne kotły odzysknicowe (z możliwością dopalania spalin wlotowych na kocioł gazem ziemnym). Dodatkowymi źródłami ciepła są gazowo-olejowe kotły szczytowe, pracujące w szczycie zapotrzebowania na ciepło lub jako rezerwowe źródło w przypadku przerw w pracy turbin. W skład układu technologicznego wchodzi następujące urządzenia, układy i systemy:

- dwie turbiny gazowe firmy General Electric (GE LM6000PF);
- dwa kotły odzysknicowe z możliwością dopalania gazem ziemnym w celu zwiększenia mocy ciepłowniczej;
- cztery kotły rezerwowo-szczytowe, opalane gazem ziemnym lub lekkim olejem opałowym firmy STANDARDKESSEL;
- układ zasilania kotłów szczytowo-rezerwowych w paliwo rezerwowe (olej opałowy lekki) – obejmujący zbiornik oleju opałowego, pompy oraz rurociągi przesyłowe do kotłowni szczytowo-rezerwowej;
- układ produkcji i odbioru energii elektrycznej – obejmujący generatory energii elektrycznej współpracujące z turbinami, transformatory blokowe i odczepowe;


- układ odbioru ciepła – obejmujący układ wody sieciowej z pompownią, odgazowywaczem, akumulator ciepła oraz układ uzupełniania strat wody;
- układ chłodniczy – obejmujący zamknięte obiegi chłodnicze turbin gazowych i sprężarki gazu ziemnego;
- układ mycia sprężarek turbin – obejmujący układy mycia zintegrowane z turbinami oraz zbiorniki wody myjącej.

4.2.1 Opis technologii


Elektrociepłownia posiada dwie identyczne turbiny gazowe (GT1, GT2) jako podstawowe jednostki wytwórcze (o łącznej mocy wytwarzania energii elektrycznej 107 MWe). Ciepło na potrzeby zasilania MSC produkowane jest w dwóch kotłach odzysknicowych (HRHWB1, HRHWB2) zasilanych spalinami wylotowymi z turbiny (o maksymalnej produkcji ciepła 238 MWt). Ogólna wizualizacja elektrociepłowni gazowej w Toruniu została przedstawiona na Rys. 4.6. Elektrociepłownia jest zasilana gazem miejskim, który trafia do stacji przygotowania gazu. Paliwo gazowe jest dystrybuowane osobnymi połączeniami do poszczególnych turbin, palników dopalających spaliny i kotłów rezerwowo-szczytowych. Gaz ziemny dostarczany jest z zewnętrznego gazociągu ze stacji gazowej wysokiego ciśnienia. W związku z wymaganiami dotyczącymi dostarczonego paliwa (czystość, temperatura i ciśnienie) wymagane jest przygotowanie jego parametrów w stacji przygotowania gazu.

Do spalania gazu w turbinie gazowej doprowadzane jest powietrze potrzebne do spalania, które poprzez czerpnię i filtry powietrza trafia do komory spalania turbiny gazowej. Dodatkowo, turbina jest wyposażona w układ anty-oblodzeniowy, służący do podgrzewania powietrza dolotowego. W trakcie pracy turbiny gazowej, praca mechaniczna wału jest zamieniana na energię elektryczną w generatorze i kierowana do sieci elektroenergetycznej poprzez transformatory blokowe. Odpowiednią temperaturę czynnika podawanego na turbinę uzyskuje się poprzez spalanie gazu w komorze spalania. Temperatura spalin wylotowych z komory spalania wynosi ok. 1400 °C. Spaliny takie są wprowadzane na turbinę gazową, gdzie rozprężają się i ochładzają się do 450-500 °C, które trafiają do kotła odzysknicowego przekazując energię do wody w kotłowych wymiennikach ciepła. Spaliny po ochłodzeniu na kotle kierowane do komina. W przypadku konieczności zwiększenia mocy cieplnej przekazywanej w kotle uruchamiane są palniki dopalające spaliny na wlocie do kotła. Gorąca woda z kotła odzysknicowego jest kierowana do sieci ciepłowniczej lub może zasilać akumulator ciepła. W celu pokrycia szczytowego zapotrzebowania uruchamiane są kotły wodne, posiadające własny komin.

Uproszczony, przepływowy schemat technologiczny układu ze wszystkimi jednostkami wytwórczymi w elektrociepłowni przedstawiono na Rys. 4.7.



Rys. 4.6. Elektrociepłownia gazowa w Toruniu



Rys. 4.7. Uproszczony schemat przepływu elektrociepłowni. DHN – miejska sieć ciepłownicza, GT – turbina gazowa, SF – palnik dopalający spaliny, HRHWB – kocioł odzysknicowy, HOB – kocioł szczytowy, ACU – akumulator ciepła

Moc elektryczna wytworzona w generatorach obu turbin zasila cały układ w energię elektryczną, a nadwyżka mocy oddawana jest do zewnętrznej sieci elektroenergetycznej. Układ wlotu powietrza umieszczony jest na dachu maszynowni i składa się z przedziału wlotowego oraz kanałów rozprowadzających powietrze wyposażonych w urządzenia filtrujące, tłumiące hałas, utrzymujące wymaganą temperaturę, podłączonych do komory wlotowej turbiny oraz do pomieszczenia turbiny i generatora.

W czasie pracy turbiny na łopatkach sprężarki osadzają się zanieczyszczenia z powietrza, które powodują obniżenie sprawności i pogorszenie stosunku mocy wyjściowej silnika do spalnego paliwa. Osady te mogą być źródłem powstawania ognisk korozji łopat oraz przewodów. Zanieczyszczenia, o których mowa usuwane są z układu przepływowego sprężarki poprzez okresowe płukanie, mycie łopatek wodą z odpowiednio dobranymi w zależności od rodzaju zanieczyszczeń dodatkami. Dodatki dobiera dostawca turbiny w oparciu o skład chemiczny zanieczyszczeń znajdujących się w powietrzu rejonu gdzie zainstalowano turbinę.

4.2.2 Turbina gazowa


W elektrociepłowni pracują dwie identyczne turbiny gazowe GE LM600PF. Turbiny zasilane gazem ziemnym oraz sprężonym powietrzem atmosferycznym umożliwiają spalanie gazu w komorze paleniskowej, a gorące spaliny napędzają wał turbiny, sprzężony z generatorem umożliwiając produkcję energii elektrycznej. Uproszczony schemat turbiny prezentuje Rys. 4.8. Turbina GE LM6000 PF jest to maszyna wyposażona w system DLE (Dry Low Emission), odznaczającą się parametrami, które gwarantują niskie emisje NO_x i CO₂ w trakcie spalania paliwa w turbinach gazowych. Jednostka jest zaprojektowana do działania w zakresie obciążeń od 20% do 100%. Turbina wywodzi się z silnika lotniczego CF6-80 firmy General Electric i została przystosowana do zastosowań związanych z wytwarzaniem energii. Turbina składa się z pięciostopniowej sprężarki niskociśnieniowej, 14-stopniowej sprężarki wysokociśnieniowej, pierścieniowej komory spalania, dwustopniowej turbiny wysokociśnieniowej oraz pięciostopniowej turbiny niskociśnieniowej. Podczas pracy jednostki, sprężarka osiowa podaje powietrze do komory spalania. W komorze spalane jest paliwo gazowe, a spaliny wprowadzone są do części turbinowej, gdzie ich energia napędza wirniki turbiny wysoko- i niskociśnieniowej z sprężarkami osiowymi oraz poprzez przekładnię mechaniczną generator.

Podstawowe dane bloku energetycznego pracującego w oparciu o turbinę LM6000PF w cyklu pracy z wodnym kotłem odzysknicowym z dopalaniem przedstawia Tab. 4.3.

Tab. 4.3. Dane technologiczne bloku z turbiną LM6000PF

Lp.	Parametry techniczne	Jednostka	Wartość
1	Moc elektryczna (mierzona na wyjściu z generatora) przy pełnym obciążeniu	MWe	30-50,6
2	Maksymalna moc cieplna netto w wodzie odprowadzanej do sieci przy pracującym palniku dopalającym spaliny wylotowe	MWt	116

Lp.	Parametry techniczne	Jednostka	Wartość
3	Sprawność elektryczna brutto przy pełnym obciążeniu w warunkach nominalnych	%	>41
4	Temperatura spalin na wylocie z turbiny gazowej	°C	420 – 517
5	Maksymalna emisja CO ₂ przy pracującym palniku dopalającym spaliny	t/h	34



Rys. 4.8. Uproszczony schemat przepływowy turbiny gazowej. 1 – Powietrze, 2 – paliwo gazowe, 3 – spaliny, 4 – energia elektryczna, 5 – woda w obiegu anty-icing


4.2.3 Kocioł odzysknicowy

Schemat ideowy kotła odzysknicowego przedstawia Rys. 4.9. Turbiny gazowe zasilają spalinami wodne kotły odzysknicowe. Spaliny na wylocie z turbiny gazowej charakteryzują się wysoką zawartością tlenu (13-16%) oraz temperaturą (420-517 °C). W celu wykorzystania entalpii fizycznej spalin opuszczających turbinę gazową, spaliny te kierowane są do kotła odzyskowego, gdzie następuje produkcja ciepła i podgrzanie wody sieciowej do temperatury 135 °C. Część wody gorącej trafia do obiegu recyrkulacji w celu zapewnienia stałej temperatury dolotowej do kotła na poziomie 60 °C. Ilość ciepła przekazana w kotle odzyskowym wynika z parametrów spalin na wylocie z kotła. Dopuszczalna temperatura spalin na wylocie z kotła odzyskowego zawiera się w przedziale 75-115 °C. Przy pracującym palniku dopalającym spaliny, temperatura wylotowa w kominie przekracza 100°C. Nominalna sprawność energetyczna kotła odzyskowego wynosi 98%. Spaliny wylotowe po schłodzeniu na kotle trafiają do emitora i opuszczają układ.

W przypadku, gdy wymagana moc cieplna kotła odzyskowego jest większa niż dostępna moc cieplna spalin opuszczających turbinę gazową, możliwe jest wykorzystanie układu dopalającego w celu zwiększenia strumienia spalin i podniesienia ich temperatury. Układ dopalający znajduje się za turbiną gazową

i przed kotłem odzyskowym. Spaliny wylotowe z turbiny gazowej trafiają do strefy dodatkowego spalania, gdzie doprowadzane jest paliwo gazowe. Ze względu na wysoką zawartość tlenu w spalinach nie ma potrzeby doprowadzania dodatkowego strumienia powietrza do spalania. Maksymalna moc cieplna kotła odzyskowego wraz z układem dopalania uzupełniającego wynosi 116 MWt. Maksymalna temperatura spalin za układem opalania uzupełniającego wynosi 820 °C.

Kocioł wodny z odzyskiem ciepła z układem opalania uzupełniającego jest podgrzewaczem ciepłowniczym kotłowym z wymuszoną cyrkulacją, pionowym przejściem gazu z niechłodzoną obudową i komorą spalania dla jednego poziomu ciśnienia. Układ opalania uzupełniającego wykorzystuje palnik kanałowy typu niskoemisyjnego. Kocioł wodny z odzyskiem ciepła znajduje się poza głównym budynkiem gdzie znajdują się turbiny i został zaprojektowany do wykorzystania w warunkach zewnętrznych. Podstawowe dane technologiczne dla kotła przedstawiono w Tab. 4.4.



Rys. 4.9. Uproszczony schemat przepływu wodnego kotła odzyskującego. 1 – Powietrze, 2 – paliwo gazowe, 3 – spaliny, 5 – woda w obiegu podgrzewu gazu, 6 – woda sieciowa

Tab. 4.4. Dane technologiczne wodnego kotła odzysknicowego

Lp.	Parametry techniczne	Jednostka	Wartość
1	Maksymalna moc cieplna turbiny gazowej (kotła wodnego z odzyskiem ciepła) bez opalania uzupełniającego	MWt	55,8
2	Maksymalna moc dopalania uzupełniającego	MWt	73
3	Minimalna moc dopalania uzupełniającego	MWt	6
4	Maksymalna temperatura za układem opalania uzupełniającego	°C	820
5	Temperatura spalin w kominie (przy niepracującym układem opalania uzupełniającego)	°C	75-85
6	Temperatura spalin w kominie (przy pracującym układem opalania uzupełniającego)	°C	85-115

Układ regulacji temperatury wody na wylocie z kotła wodnego z odzyskiem ciepła utrzymuje temperaturę wody poprzez zmienianie przepływu wody do kotła lub mocy palnika pomocniczego. Jeżeli nie pracuje palnik, regulator temperatury wody na wylocie z zaworu regulacyjnego przepływu wody utrzymuje stałą wartość temperatury wody zadaną przez operatora (135°C). W przypadku pracującego palnika, temperatura wylotowa regulowana jest przy pomocy zmieniania mocy palnika pomocniczego. Regulator temperatury wody na wylocie z zaworu regulacyjnego paliwa utrzymuje stałą wartość temperatury wody zadaną przez operatora (135°C) poprzez zmiany wartości zadanej mocy palnika pomocniczego w ramach regulacji mocy palnika.

4.2.4 Akumulator ciepła

Urządzeniem akumulacji ciepła jest bezciśnieniowy zbiornik akumulatora ciepła (ACU), odpowiednio zaizolowany dla zminimalizowania strat ciepła. Pojemność cieplna akumulatora wynosi 600 MWh. Akumulator jest ładowany i rozładowywany maksymalnie z mocą 52 MWt. Objętość czynna wody zgromadzonej w akumulatorze wynosi 12 tys. m³. Akumulator jest połączony układem rurociągów wody sieciowej z pompami wody (pompy wody gorącej i pompy wody zimnej) oraz poprzez te pompy jest wpięty w układ wyprowadzania mocy cieplnej do układu miejskiej sieci ciepłowniczej. Akumulacja gorącej wody w zasobniku ciepła umożliwia zwiększenie produkcji energii elektrycznej w szczytowych okresach zapotrzebowania na moc elektryczną, dodatkowo może eliminować pracę kotłów szczytowych w okresach przejściowych.

Akumulator ciepła może pracować w dwóch cyklach:

- ładowania – zasobnik ciepła zasilany jest gorącą wodą i jednocześnie odprowadzana jest woda zimna do obiegu wody sieciowej,
- rozładowywania – zasobnik ciepła zasilany jest wodą o temperaturze powrotu z sieci ciepłowniczej i jednocześnie odprowadzana jest woda gorąca do mieszalnika przed wejściem do miejskiej sieci ciepłowniczej.

Ze względu na maksymalną dopuszczalną temperaturę wody do zasilania akumulatora ciepła konieczne jest jej zmieszanie z wodą zimną. Część wody gorącej o temperaturze

135°C, która podgrzana została w kotłach odzyskowych oraz kotłach wodnych jest mieszana z zimną wodą, która pochodzi z rozładowywania akumulatora ciepła. Mieszanie ma na celu uzyskanie temperatury wody za mieszalnikiem równej 95°C.

4.2.5 Kocioł wodny (szczytowy)

Analizowana elektrociepłownia gazowa wyposażona jest w cztery zainstalowane przepływowe kotły wodne (HOB1-4). Główną funkcją ich pracy jest pokrywanie szczytowego zapotrzebowania na ciepło, w przypadku, gdy zapotrzebowanie na moc cieplną przekracza zdolności wytwórcze układu turbin gazowych z kotłami odzysknicowymi. Ze względu na ich budowę oraz układ połączeń w systemie podgrzewu wody sieciowej w elektrociepłowni mogą również pełnić rolę urządzeń podstawowych. Podstawowym paliwem dla kotłów wodnych jest gaz ziemny wysokometanowy. Możliwe jest również zasilanie kotłów paliwem olejowym, gdyż na stałe w komorze paleniskowej zabudowane są oprócz palników gazowych również palniki olejowe.

Do komory spalania doprowadzane jest paliwo (gaz lub olej) oraz powietrze do spalania. Spaliny z komory spalania kierowane są do wymiennika spalinowego, gdzie następuje podgrzanie wody sieciowej. Spaliny z kotła wodnego trafiają do emitora i opuszczają układ. Woda sieciowa z miejskiej sieci ciepłowniczej podgrzewana jest w kotle wodnym do temperatury 135 °C. Część wody gorącej trafia do obiegu recyrkulacji w celu zapewnienia stałych parametrów pracy kotła HOB.


Kotły wodne podstawowo zasilane są gazem wysokometanowym. Zamiana paliwa zasilającego z gazu na olej odbywa się w przypadku, gdy zużycie gazu w układzie przekracza maksymalną wartość przyłącza gazowego elektrociepłowni. Maksymalna moc cieplna kotła wodnego wynosi 30 MWt. Nominalna sprawność energetyczna kotła wodnego wynosi 95,5% przy zasilaniu paliwem gazowym.

4.3 Produkcja ciepła i energii elektrycznej w elektrociepłowni

Poziom zapotrzebowania na ciepło w systemie ciepłowniczym uwarunkowany jest w głównej mierze potrzebami na cele ogrzewania budynków oraz przygotowania ciepłej wody użytkowej. Zapotrzebowanie na ciepło przez odbiorców końcowych, wykazuje zróżnicowanie zarówno dobowe jak i sezonowe. Na Rys. 4.10 przedstawiono godzinowy przebieg mocy cieplnej oddawanej do analizowanej sieci ciepłowniczej wraz z godzinowym przebiegiem temperatury otoczenia w skali miasta. Przedstawione dane obejmują okres dwóch pełnych lat kalendarzowych. Podczas okresu grzewczego (w miesiącach od października do maja), moc cieplna jest uzależniona w głównej mierze od warunków atmosferycznych. Poza sezonem grzewczym (w miesiącach od czerwca do września), produkowane w źródle ciepło jest przeznaczone na pokrycie potrzeb wynikających z przygotowania ciepłej wody użytkowej u odbiorców końcowych.

Całkowite roczna produkcja ciepła przez EC w 2021r. wyniosła 573 880 MWh. Największe chwilowe zapotrzebowanie na ciepło odnotowano w styczniu i wynosiło 240

MWt. Najmniejsze zapotrzebowanie zostało odnotowane w lipcu i wynosiło 19 MW. Różnica między minimalnym, a maksymalnym zapotrzebowaniem na ciepło w styczniu wyniosła ok. 140 MWt i była w głównej mierze spowodowana zmianami temperatury otoczenia oraz koniecznością dostarczania wody grzewczej na cele centralnego ogrzewania. Tab. 4.5. przedstawia dane dotyczące sumarycznej produkcji ciepła w poszczególnych miesiącach oraz w całym 2021 roku, wraz z minimalną i maksymalną mocą cieplną.




Rys. 4.10 Godzinowy przebieg mocy cieplnej na zasilaniu sieci ciepłowniczej oraz temperatury otoczenia

Tab. 4.5. Sumaryczna produkcja ciepła w poszczególnych miesiącach oraz w całym 2021 roku, wraz z minimalną i maksymalną mocą cieplną



Miesiąc	Sumaryczna produkcja ciepła	Minimalna i maksymalna moc chwilowa
Styczeń	90 537 MWh	95,01 / 238,27 MW
Luty	75 338 MWh	57,75 / 225,63 MW
Marzec	71 971 MWh	39,31 / 161,50 MW
Kwiecień	44 905 MWh	37,82 / 128,33 MW
Maj	29 637 MWh	23,05 / 110,36 MW
Czerwiec	17 410 MWh	16,96 / 31,45 MW
Lipiec	16 437 MWh	13,80 / 25,40 MW
Sierpień	14 650 MWh	14,41 / 28,70 MW
Wrzesień	19 140 MWh	19,27 / 63,66 MW
Październik	43 976 MWh	31,51 / 108,12 MW
Listopad	63 893 MWh	53,72 / 141,59 MW
Grudzień	85 977 MWh	89,86 / 212,01 MW
SUMA	573 880 MWh	-

Wykres uporządkowany produkowanej mocy cieplnej przez jednostki wytwórcze wchodzące w skład elektrociepłowni przedstawia Rys. 4.11. Kocioł odzysknicowy HRHWB pracuje w podstawie, przez cały okres sezonu grzewczego oraz letniego. W lecie współpracuje z akumulatorem ciepła (do którego akumulowane są nadwyżki ciepła). Przez ok. 1000 godzin w ciągu roku, akumulator jest rozładowywany i stanowi jedyne źródło ciepła w systemie (gdy turbina gazowa jest w postoju). W okresie zwiększonego zapotrzebowania na ciepło podczas sezonu grzewczego, uruchamiany jest palnik dopalający spaliny z turbiny SF, zwiększający moc cieplną kotła do wymaganego przez sieć poziomu. Przez ok. 4000 godzin w ciągu roku, pracują w jednym czasie dwie turbiny. Szczytowe zapotrzebowanie na ciepło pokrywane jest przez kotły rezerwowo-szczytowe HOB.

Z przedstawionej analizy rozkładu mocy jednostek wytwórczych, można wywnioskować, że widać znaczące różnice w trakcie trwania roku kalendarzowego. W celu przeprowadzenia oceny charakterystyki produkcji ciepła w elektrociepłowni, wymagane jest podzielenie całego roku kalendarzowego na okresy pracy elektrociepłowni. W okresie zimowym, kiedy występuje największe zapotrzebowanie na ciepło, do pokrycia zapotrzebowania wymagane jest uruchomienie kotłów odzysknicowych z układem dopalania oraz szczytowych kotłów wodnych. Rys. 4.12a przedstawia pokrycie zapotrzebowania na ciepło podczas dwóch wybranych dni w styczniu. W tym okresie, uruchamiane były kotły odzysknicowe, układ dopalania i kotły szczytowe. Na przedstawionym wykresie na Rys. 4.12a, widać również charakterystyczne spadki i wzrosty zapotrzebowania na ciepło wynikające z charakterystyki zapotrzebowania na ciepłą wodę użytkową i ogrzewania w okresie zimowym.




Rys. 4.11. Wykres czasu występowania mocy poszczególnych jednostek wytwórczych w ciągu roku: HRHWB1, HRHWB2 – kotły odzysknicowe, SF1, SF2 – palniki dopalające, HOB1, HOB2, HOB3, HOB4 – wodne kotły szczytowe, AKU-akumulator ciepła



Rys. 4.12. Przebieg produkowanej przez jednostki wytwórcze (a) mocy cieplnej (b) mocy elektrycznej podczas okresu zimowego

Latem pracuje tylko jeden z bloków, ponieważ chwilowe zapotrzebowanie na ciepło w MSC nie przekracza 30 MWt i jest mniejsze od ciepła wytwarzanego przez jeden kocioł odzysknicowy. Na rysunku Rys. 4.13a i Rys. 4.13b przedstawiono odpowiednio dobowy profil produkcji ciepła przez HRHWB-1 i turbinę GT-1 w wybranych dniach lipca. W okresie letnim produkcja ciepła prowadzona jest z uwzględnieniem współpracy jednostki z akumulatorem ciepła w celu optymalizacji produkcji wytwarzania energii elektrycznej. W momencie szczytowych cen energii, pracuje jedna GT z maksymalną wydajnością, a wytworzone ciepło jest dostarczane zarówno do MSC, jak i do

akumulatora. Akumulator jest rozładowywany podczas postoju jednostki, a zapotrzebowanie MSC pokrywane jest ciepłem z rozładowania zasobnika. Z analizy Rys. 4.13b wynika, że turbina pracująca z pełnym obciążeniem, wykazuje zróżnicowany poziom produkcji energii elektrycznej, co jest spowodowane zmianami temperatury powietrza dolotowego do kompresora.



Rys. 4.13. Przebieg produkowanej przez jednostki wytwórcze (a) mocy cieplnej (b) mocy elektrycznej podczas okresu letniego

5 Prognozowanie zapotrzebowania na ciepło metodami uczenia nadzorowanego

Model predykcyjny do przewidywania godzinowego zapotrzebowania na ciepło oddawane przez rozważaną elektrociepłownię do sieci ciepłowniczej został opracowany z wykorzystaniem metod regresyjnego uczenia nadzorowanego. W podejściu tym, zakłada się, że zmienna prognozowana Y (moc cieplna) jest uzależniona od predyktorów $X = (X_1, X_2, \dots, X_p)$. Zależność pomiędzy zmienną Y , a predyktorami może być przedstawiona w poniższej postaci [94]:

$$Y = f(X) + \varepsilon \quad (5.1)$$

W powyższym wzorze, f jest nieznaną funkcją predyktorów X oraz ε jest błędem losowym, niezależnym od X i ma rozkład normalny $N(0, \sigma^2)$ [94]. Uczenie modelu polega na estymowaniu funkcji f , w celu opisanie zależności pomiędzy zmienną prognozowaną, a predyktorami, zgodnie z poniższą relacją.


$$\hat{Y} = \hat{f}(X) \quad (5.2)$$

gdzie $\hat{f}$ stanowi estymację funkcji f , a $\hat{Y}$ reprezentuje wynikową prognozę zmiennej Y . Dokładność wyznaczenia prognozy $\hat{Y}$ uzależniona jest od dwóch wielkości – błędu redukowalnego oraz nieredukowalnego, ponieważ w rzeczywistości $\hat{f}$ nigdy nie jest idealną estymacją funkcji f . Błąd wynikający z błędu estymacji może być redukowalny na skutek zwiększania dokładności estymacji f , poprzez zastosowanie odpowiednich algorytmów do prognozowania. Przyjmując, że mamy idealną estymację f , tak że estymowana odpowiedź przyjmuje formę $\hat{Y} = f(X)$, to predykcja $\hat{Y}$ wciąż będzie obciążona błędem. Wynika to z zależności zmiennej Y od nieredukowalnego błędu losowego ε [94].


5.1 Dane uczące model predykcyjny

Na potrzeby selekcji zmiennych uczących model do prognozowania zapotrzebowania na ciepło w badanym w pracy przypadku, dokonano analizy wpływu poszczególnych danych na moc cieplną wyprowadzaną z badanej elektrociepłowni do sieci ciepłowniczej. Do badań wykorzystano zestaw danych zagregowany w rozdzielczości średnio-godzinowej, obejmujący okres dwóch pełnych lat kalendarzowych (2021-2022). Jako dane pogodowe wykorzystano dane pochodzące od zewnętrznego dostawcy prognozy pogody dla miasta Toruń. Moc cieplna oddawana do sieci ciepłowniczej pochodziła z układu pomiarowego elektrociepłowni (była


obliczona na podstawie pomiaru temperatur na zasilaniu i powrocie oraz objętościowego przepływu wody sieciowej, zgodnie z zależnością (4.1)). Na Rys. 5.1 przedstawiono wykres obrazujący statystykę rozkładu mocy cieplnej na przestrzeni poszczególnych miesięcy roku. Z analizy wykresu wynika, że godzinowa moc cieplna fluktuowała w poszczególnych miesiącach, co wynikało z chwilowych zmian warunków atmosferycznych, czy specyfiki zachowania odbiorców ciepła.



Rys. 5.1 Rozkład mocy cieplnej w poszczególnych miesiącach roku




Rys. 5.2. Chwilowa moc cieplna w zależności od temperatury otoczenia




Rys. 5.3. Chwilowa moc cieplna w zależności od prędkości wiatru

Na Rys. 5.2 zaprezentowano w rozdzielczości godzinowej, wykres rozrzutu pomiędzy temperaturą otoczenia, a mocą cieplną dla badanego okresu czasu. Dane zaprezentowano w podziale na okres zimowy podczas sezonu grzewczego (obejmujący miesiące od grudnia do marca – kiedy temperatura otoczenia jest najniższa) oraz okres przejściowy (obejmujący miesiące od kwietnia do maja oraz od października do listopada – kiedy występuje okresowo relatywnie wysoka temperatura otoczenia i natężenie promieniowania słonecznego). W okresie przejściowym następuje częsta zmiana nastaw parametrów wody sieciowej na wyprowadzeniu ciepła ze źródła do miasta, z uwagi na dynamicznie zmieniającą się na przestrzeni doby pogodę. Powoduje to dodatkowe trudności w przewidywaniu profilu zapotrzebowania na ciepło, z uwagi na dynamiczne efekty związane ze stratami ciepła pod wpływem gwałtownych zmian strumienia wody sieciowej i temperatury zasilania. Ponadto, w okresie przejściowym następuje sukcesywne przełączanie się węzłów ciepła na tryb poboru ciepła sieciowego wyłącznie na ciepłą wodę użytkową. Analizując wykres na Rys. 5.2 zauważyć można, że w miesiącach zimowych, temperatura otoczenia jest najsilniej skorelowana z mocą cieplną. W miesiącach przejściowych, zależność ta przybiera charakter bardziej nieliniowy, a rozrzut mocy przy tych samych temperaturach otoczenia jest większy. Biorąc to pod uwagę, w prognozowaniu zapotrzebowania należy też uwzględnić pozostałe dane klimatyczne. W okresie przejściowym uwidaczniają się również efekty związane z akumulacyjnością ciepła w budynkach pod wpływem zwiększonego promieniowania słonecznego [95]. Na bieżący poziom mocy cieplnej w systemie ciepłowniczym wpływa również prędkość wiatru (Rys. 5.3) oraz natężenie promieniowania słonecznego (Rys. 5.4), wilgotność względna (Rys. 5.5), które mają wpływ na poziom temperatury odczuwalnej, a tym samym na poziom zapotrzebowania na ciepło.



Rys. 5.4. Chwilowa moc cieplna w zależności od natężenia promieniowania słonecznego



Rys. 5.5. Chwilowa moc cieplna w zależności od wilgotności względnej powietrza atmosferycznego

W Tab. 5.1 zestawiono współczynniki korelacji Pearson'a oraz Spearman'a pomiędzy analizowanymi danymi pogodowymi, a mocą cieplną na podstawie danych z wyżej przedstawionych wykresów. Współczynnik korelacji Pearson'a (wzór (5.3)) pozwala na określenie, czy istnieje związek liniowy między dwoma zmiennymi – jeśli tak, to pozwala określić jaka jest jego siła oraz jaki ma on charakter tj. czy jest dodatni (korelacja pozytywna) czy ujemny (korelacja negatywna). Korelacja Spearman'a (wzór (5.4)) w odróżnieniu od współczynnika Pearsona, pokazuje dowolną monotoniczną zależność, także nieliniową [96]. W okresie zimowym, korelacja pomiędzy mocą cieplną, a temperaturą otoczenia jest najsilniejsza – współczynnik Pearson'a przyjmuje wartość -0,94. Podczas okresu przejściowego, korelacja liniowa jest słabsza, a współczynnik Spearman'a przewyższa wartość współczynnika

Pearson'a. Pozostałe zmienne pogodowe jak natężenie promieniowania słonecznego, prędkość wiatru, wilgotność względna są skorelowane na słabszym poziomie.

$$r_{pearson} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (5.3)$$

$$r_{spearman} = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (5.4)$$

gdzie:

x_i i y_i - kolejne wartości zmiennych x i y

$\bar{x}$ i $\bar{y}$ - średnie wartości zmiennych x i y


d_i - różnice między rangami odpowiadającymi jednej zmiennej x i drugiej zmiennej y

n - liczba obserwacji


Tab. 5.1 Współczynniki korelacji Pearson'a oraz Spearman'a pomiędzy danymi pogodowymi, a mocą cieplną oddawaną do sieci ciepłowniczej

Zmienna	Okres zimowy		Okres przejściowy	
	Korelacja Pearson'a	Korelacja Spearman'a	Korelacja Pearson'a	Korelacja Spearman'a
Temperatura otoczenia	-0,94	-0,93	-0,80	-0,82
Prędkość wiatru	-0,09	-0,09	-0,06	-0,12
Natężenie promieniowania słonecznego	-0,28	-0,25	-0,27	-0,24
Wilgotność względna	0,17	0,14	0,02	-0,04
Ciśnienie atmosferyczne	0,01	-0,01	-0,01	-0,02

Poza ciepłem produkowanym na potrzeby ogrzewania budynków, na poziom zapotrzebowania na ciepło wpływa również profil zapotrzebowania na ciepłą wodę użytkową. Na Rys. 5.6 przedstawiono statystyczny rozkład mocy cieplnej w poszczególnych godzinach doby okresu letniego. Uwidoczniony jest spadek produkcji ciepła podczas nocy i gwałtowny wzrost w godzinach wieczornych. W trakcie sezonu letniego, profil produkcji ciepła ulega również wahaniom w skali tygodnia. Na Rys. 5.7 przedstawiono rozkład mocy cieplnej w podziale na dni tygodnia. Jak pokazuje wykres, podczas weekendu (dzień nr 6 i dzień nr 7) średniodobowa moc cieplna jest na niższym poziomie w porównaniu do dni roboczych.



Rys. 5.6. Rozkład mocy cieplnej w okresie letnim w poszczególnych godzinach doby. 1SD – odchylenie standardowe




Rys. 5.7. Rozkład mocy cieplnej w okresie letnim w poszczególnych dniach tygodnia. 1SD – odchylenie standardowe

5.1.1 Dokładność prognozy danych pogodowych


Podczas budowania modelu prognostycznego i etapu jego uczenia, wykorzystuje się dane faktyczne (wykonana moc cieplna jest uczona w oparciu o rzeczywiste dane pogodowe). Na etapie prognozowania z użyciem uprzednio nauczonego modelu, niezbędne jest również zaprognozowanie danych, które zostały użyte do trenowania modelu. Na poniższych wykresach na Rys. 5.8 zaprezentowano dokładność poszczególnych danych pogodowych w horyzoncie doby następnej


(wyznaczonej o godz. 6:00 w dobie poprzedzającej). Dokładność została oceniona z użyciem błędu średniokwadratowego na podstawie analizy porównawczej wartości rzeczywistych i prognozowanych. Z analizy wykresów wynika, że błąd prognozy pogody jest zwiększony dla miesięcy z okresu przejściowego i letniego. Średniomiesięczny błąd RMSE temperatury otoczenia w okresie zimowym nie przekracza 1,3 °C, a podczas kwietnia wzrasta do 2 °C. Natężenie promieniowania słonecznego obarczone jest błędem w okresie przejściowym do 90 W/m². Błąd prognozy prędkości wiatru wynosi 2-3 m/s, a wilgotności względnej pomiędzy 6-11 %. Uwzględnienie w modelu prognostycznym natężenia promieniowania słonecznego, potencjalnie doprowadzi do opracowania dokładniejszego modelu, jednak należy mieć na uwadze, że w wyniku błędów prognozy pogody, szacowanie prognozowanej mocy cieplnej może być obciążone zwiększonym błędem.

a)



b)





Rys. 5.8. Błąd RMSE prognozy poszczególnych danych klimatycznych (a) temperatury otoczenia (b) natężenia promieniowania słonecznego (c) prędkości wiatru (d) wilgotności względnej

5.2 Uogólniony Model Addytywny GAM

W niniejszej rozprawie do budowy modelu predykcyjnego zapotrzebowania na ciepło wykorzystano metodę Uogólnionego Modelu Addytywnego GAM, który jest nieparametrycznym rozszerzeniem Uogólnionego Modelu Liniowego (ang. Generalized Linear Model GLM), w którym związek między zmienną zależną, a predyktorami wyraża się za pomocą tzw. funkcji wygładzających (ang. smoothing function) [97]. W przeciwieństwie do modeli parametrycznych, modele nieparametryczne nie są

ograniczone do określonej z góry postaci, a ostateczna postać funkcji wygładzających model jest dobierana na etapie uczenia modelu. Z tego względu wydają się interesującym narzędziem prognozowania zwłaszcza w przypadku nieliniowych zależności pomiędzy predyktorami a zmienną prognozowaną. Model GAM można formalnie zapisać za pomocą następujących równań [97]:

$$Y \sim ED(g^{-1}(\eta), \phi) \quad (5.5)$$

$$\eta = \alpha + s_1(X_1) + \dots + s_p(X_p) \quad (5.6)$$

gdzie:

$Y = (y_1, y_2, \dots, y_n)$ – wektor zmiennej prognozowanej z n obserwacjami

$ED(g^{-1}(\eta), \phi)$ – wykładniczy rozkład rodziny z parametrem skali ϕ

$g^{-1}(\eta)$ – funkcja łączenia, która łączy wartość oczekiwaną ze zmiennymi predykcyjnymi

$X_1 = (x_1, x_2, \dots, x_n)$ – wektor zmiennych objaśniających model z n obserwacjami

p – liczba zmiennych objaśniających model

α – współczynnik poprawkowy

$s_1, \dots, s_p$ – nieznane funkcje wygładzające

W modelu uogólnionym zakłada się, że każdy wynik zmiennej zależnej, generowany jest na podstawie określonego rozkładu w rodzinie wykładniczej. W przypadku ciągłych liczb rzeczywistych, można zastosować rozkład Gaussa [98]. Alternatywnie, może zostać zastosowany rozkład Gamma do prognozowana ciągłej, nieujemnej zmiennej. W modelu GAM, nieznane (nieparametryczne) funkcje wygładzające zmienne objaśniające łączone są ze zmienną zależną za pomocą funkcji łączenia. Funkcje wygładzające s można przedstawić jako sumę odcinkowych funkcji bazowych b i odpowiadających im współczynników regresji β , jak przedstawiono w równaniu (5.7). Miejsca, w których łączą się funkcje bazowe, nazywane są węzłami. Poziom gładkości funkcji wygładzających zależy od liczby węzłów i ich umiejscowienia.

$$s(x) = \sum_{k=1}^K b_k(x) \beta_k \quad (5.7)$$

gdzie:

K – wymiar podstawowy, określający liczbę węzłów

k – węzeł, gdzie funkcje bazowe są stosowane na predyktorze (zwykle równomiernie rozłożone)

β_k – nieznane współczynniki

b_k – postać funkcji wygładzającej

Jeśli mamy kilka predyktorów objaśniających zmienną prognozowaną, funkcje wygładzające można zapisać w postaci wektora funkcji gładkich s i wektora β z odpowiednimi współczynnikami (równanie (5.8)). Macierz X wyprowadzona z funkcji bazowych przedstawiona jest w równaniu (5.9):

$$\mathbf{s} = [s(\mathbf{X}_1), s(\mathbf{X}_2), \dots, s(\mathbf{X}_p)]^T = \mathbf{X}\boldsymbol{\beta} \quad (5.8)$$

$$\mathbf{X} = \begin{bmatrix} b_1(x_1) & b_2(x_1) & b_3(x_1) & \dots \\ b_1(x_2) & b_2(x_2) & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix} \quad (5.9)$$

Wykorzystując powyższe zależności, równanie (5.6) może być przedstawione w następującej postaci:

$$\mathbf{y} = g^{-1}(\mathbf{X}\boldsymbol{\beta}) + \boldsymbol{\varepsilon} \quad (5.10)$$

gdzie:

$\mathbf{y}$ – wektor z wartościami zmiennej prognozowanej

$\boldsymbol{\beta}^T = (\alpha, \boldsymbol{\beta}_1^T, \boldsymbol{\beta}_2^T, \dots, \boldsymbol{\beta}_p^T)$ – zawiera wszystkie współczynniki bazowe dla każdej z funkcji wygładzających

$\boldsymbol{\varepsilon}$ – wektor niezależnych zmiennych losowych

Estymację współczynników w modelu GAM uzyskuje się metodą najmniejszych kwadratów ze współczynnikiem kary λ – jak przedstawiono w równaniu (5.11), gdzie współczynniki λ kontrolują wagę, jaką należy nadać celowi wygładzenia. Współczynnik λ nazywany jest także parametrem kary, który zapobiega nadmiernemu dopasowaniu do zmiennej prognozowanej.

$$\hat{\boldsymbol{\beta}} = \underset{\boldsymbol{\beta}}{\operatorname{argmin}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2 + \lambda_1 \int [s_1''(x_1)]^2 dx_1 + \dots + \lambda_p \int [s_p''(x_p)]^2 dx_p \quad (5.11)$$

Wyrażenie w równaniu (5.11) będące przedmiotem minimalizacji można zapisać zgodnie z równaniem, gdzie macierz kar $\mathbf{S}$ jest macierzą znanych współczynników:

$$\|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2 + \sum_{j=1}^p (\lambda_j \boldsymbol{\beta}^T \mathbf{S}_j \boldsymbol{\beta}) \quad (5.12)$$

W powyższym równaniu, problem polega na określeniu parametru wygładzania λ . Jedną z możliwości określenia optymalnej wartości jest zastosowanie selekcji wstecznej [99]. Wood [100] zaproponował estymację przy użyciu kryteriów Uogólnionej Walidacji Krzyżowej (GCV) – równanie (5.13). W równaniu (5.13) $tr(\mathbf{F}_\lambda)$ jest efektywnym stopniem swobody modelu, a $\mathbf{F}_\lambda$ można zapisać jak w równaniu (5.14).

$$GCV(\lambda) = \frac{n \|\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}_\lambda\|^2}{\{n - tr(\mathbf{F}_\lambda)\}^2} \quad (5.13)$$

$$\mathbf{F}_\lambda = (\mathbf{X}^T \mathbf{X} + \mathbf{S}_\lambda)^{-1} \mathbf{X}^T \mathbf{X} \quad (5.14)$$

gdzie:

$$\mathbf{S}_\lambda = \sum_j \lambda_j \mathbf{S}_j$$

Model GAM z funkcją rodziny rozkładów Gaussa zakłada, że reszty modelu mają rozkład identyczny i niezależny. W przypadku regresji szeregów czasowych założenie to nie jest do końca spełnione, ponieważ obecne wartości szeregów czasowych są silnie skorelowane z wartościami przeszłymi, więc błędy modelu również będą potencjalnie skorelowane. Zjawisko to nazywa się autokorelacją. Włączenie modelu autoregresyjnego (AR) dla błędów w modelu GAM może rozwiązać ten problem [101]. Zatem, składnik błędu w równaniu (5.10) można rozszerzyć na następującą relację z modelem autoregresyjnym rzędu R :

$$\varepsilon_i = c + \sum_{j=1}^R \phi_j \varepsilon_{i-j} + v_i \quad (5.15)$$

gdzie:

i – i -ta obserwacja

ϕ_j – nieznany współczynnik

v_i – biały szum

c – stała

5.2.1 Przykład wykorzystania algorytmu GAM do prognozy mocy cieplnej

W niniejszym podrozdziale zaprezentowano sposób uczenia modelu GAM. Dla uproszczenia przyjmijmy, że w modelu GAM prognozowana jest moc cieplna z użyciem jednej zmiennej (temperatury otoczenia). Zależność zmiennej prognozowanej od objaśniającej model można przedstawić zgodnie ze wzorem (5.16).

$$Q_i = \alpha + s(T_i) + \varepsilon_i = \alpha + \sum_{k=1}^K b_k(T_i) \beta_k + \varepsilon_i \quad (5.16)$$

gdzie:

Q_i – i -ta obserwacja mocy cieplnej

T_i – i -ta obserwacja temperatury otoczenia

α – stały współczynnik poprawkowy

$\sum_{k=1}^K b_k(T_i) \beta_k$ – funkcja wygładzająca predyktor

Uczenie modelu polega na wyznaczeniu nieznanych współczynników w równaniu (5.16), wykorzystując dane uczące model. Na Rys. 5.9 przedstawiono wykres obrazujący zbiór temperatur otoczenia, który został użyty do dopasowania modelu prognozowania mocy cieplnej w równaniu (5.16). Rys. 5.10 przedstawia otrzymaną na drodze uczenia modelu postać funkcji wygładzającej. Jako funkcję bazową zastosowano splajn kubiczny, który definiuje równanie (5.17).

$$s(T) = a_j^-(T)\beta_j + a_j^+(T)\beta_{j+1} + c_j^-(T)\delta_j + c_j^+(T)\delta_{j+1}, \text{ dla } T_j \leq T \leq T_{j+1} \quad (5.17)$$

gdzie:

$$\beta_j = f(T_j)$$

$$\delta_j = f''(T_j)$$

$$a_j^-(T) = \frac{T_{j+1}-T}{T_{j+1}-T_j}$$

$$a_j^+(T) = \frac{T-T_j}{T_{j+1}-T_j}$$


$$c_j^-(T) = \frac{\left[\frac{(T_{j+1}-T)^3}{T_{j+1}-T_j} - T_{j+1}-T_j(T_{j+1}-T) \right]}{6}$$

$$c_j^+(T) = \frac{\left[\frac{(T-T_j)^3}{T_{j+1}-T_j} - (T_{j+1}-T_j)(T-T_j) \right]}{6}$$


Wyznaczone na etapie dopasowania modelu współczynniki funkcji wygładzającej zmienną objaśniającą przedstawiono w Tab. 5.2.

Tab. 5.2 Wartości wyznaczonych współczynników w modelu

Współczynnik	α	β_1	β_2	β_3	β_4	β_5	β_6	β_7	β_8	β_9
Wartość	93,15	-18,33	-2,91	3,08	-3,41	-0,78	1,89	-0,72	-20,98	-2,91




Rys. 5.9. Zależność mocy cieplnej od temperatury otoczenia




Rys. 5.10. Kształt funkcji wygładzającej temperaturę otoczenia – linia ciągła, przedział graniczności na poziomie 95% – linie przerywane

Na Rys. 5.11 przedstawiono wartość współczynnika λ , kontrolującego poziom dopasowania funkcji wygładzającej w relacji do wartości uogólnionej korelacji krzyżowej GCV. Najmniejszą wartość funkcji GCV otrzymano dla $\lambda = 0.142$. Im większa wartość współczynnika, tym funkcja jest bardziej „gładka”. Dla mniejszych wartości współczynnika λ funkcja jest bardziej „kręta” i bardziej dopasowana do danych uczących model. Zbyt nadmierne dopasowanie funkcji wygładzającej prowadzi do zwiększonej dokładności modelu na danych uczących, jednak może prowadzić do zjawiska tzw. przeuczenia modelu (ang. overfitting) objawiającego się pogorszeniem dokładności na nowych danych testujących model [102].



Rys. 5.11. Wartość funkcji GCV w zależności od współczynnika kary λ



Rys. 5.12. Prognozowany profil mocy cieplnej w oparciu o model GAM przy zastosowaniu różnych postaci funkcji wygładzającej oraz rozkładu eksponentialnego.

W modelu GAM można zastosować inne postacie funkcji wygładzających oraz inną rodzinę funkcji eksponentialnej [103]. Na Rys. 5.12 przedstawiono wynik prognozy mocy cieplnej w wybranej dobie, dla różnych funkcji wygładzających oraz dwóch rozkładów eksponentialnych (rozkład Gaussa oraz rozkład Gamma). Analizowano zastosowanie splajnu kubicznego „cr”, splajnu Duchon’a „ds”, splajnu typu B-spline „bs”, splajnu typu P-spline „ps”, splajnu thin plate „tp”. Z analizy wykresu wynika, że niezależnie od rodzaju funkcji wygładzającej i rozkładu z rodziny funkcji eksponentialnych, uzyskano zbliżone wartości w prognozowaniu zmiennej docelowej.


5.3 Model prognozowania zapotrzebowania na ciepło w sezonie grzewczym

Schemat ideowy opracowanego modelu do prognozowania zapotrzebowania na ciepło został przedstawiony na Rys. 5.13. Model generuje prognozy mocy cieplnej oddawanej przez badaną elektrociepłownię do miejskiej sieci ciepłowniczej w podziale na godziny doby następnej, liczonej od północy włącznie. Schemat działania modelu jest następujący:

- Każdorazowo przed przeliczeniem prognoz mocy cieplnej w dobie bieżącej (n) dla horyzontu doby następnej ($n+1$), model jest uczony z wykorzystaniem danych treningowych z przesuwnego okna czasowego, obejmującego poprzedzające doby. Przyjęty sposób kalibracji modelu prowadzi do bieżącego dostosowywania się do aktualnej specyfiki produkcji ciepła na zasilaniu sieci ciepłowniczej. Podczas kalibracji modelu, model jest uczony w oparciu o faktyczne dane pogodowe i faktyczną moc cieplną.

- Wraz z nadejściem prognozy danych pogodowych (dla tych samych zmiennych co podczas nauki modelu) dla następnej doby (o godz. 6:00 w dobie n), uprzednio nauczony model jest wykorzystywany do wyznaczenia prognozowanego zapotrzebowania na ciepło (w dobie $n+1$). Moment generowania prognozy jest uwarunkowany koniecznością opracowania planu produkcji ciepła w elektrociepłowni w związku z koniecznością zgłoszenia wolumenów energii elektrycznej na rynku dnia następnego do godz. 10:30.

Model prognozowania zapotrzebowania na ciepło został zbudowany i przetestowany na danych historycznych, pochodzących z eksploatacji badanego systemu ciepłowniczego. Model wykonano z wykorzystaniem pakietu *mgcv* [104], który zawiera biblioteki z implementacją metody *GAM* w niekomercyjnym środowisku programistycznym *R* [105].



Rys. 5.13. Schemat ideowy uczenia modelu danymi z przesuwne w czasie okna treningowego

Podczas budowania modelu, prowadzono badania mające na celu wybór docelowego rozwiązania, które będzie zaimplementowane w tworzonego narzędziu planistycznym. Analizowano zastosowanie dziewięciu modeli predykcyjnych, zróżnicowanych pod kątem algorytmów predykcyjnych i danych uczących modele. Równania opisujące zależność mocy cieplnej od predyktorów w poszczególnych modelach przedstawiono poniżej (wzory od (5.18) do (5.26)). Modele $m03$ do $m09$ należą do modeli z rodziny *GAM*, w których uwzględniono addytywny zmiennych poprzez zastosowanie funkcji wygładzających. W modelu $m09$ zastosowano metodę korelacji błędów modelem autoregresyjnym (AR) rzędu $R=1$, zgodnie ze wzorem (5.15). W algorytmach *GAM* zastosowano splajn kubiczny (5.17), jako funkcję bazową oraz rozkład Gaussa jako rozkład eksponentialny. W poniższej tabeli - Tab. 5.2 zestawiono analizowane modele wraz z wykazem zmiennych objaśniających.

Tab. 5.3 Analizowane modele predykcyjne zapotrzebowania na ciepło

Model	Algorytm	Zmienne uczące model
<i>m01</i>	Regresja liniowa	<i>Temp</i> – temperatura otoczenia, °C
<i>m02</i>	Regresja eksponentyjna	<i>Temp</i> – temperatura otoczenia, °C
<i>m03</i>	Uogólniony Model Addytywny GAM	<i>Temp</i> – temperatura otoczenia, °C
<i>m04</i>	Uogólniony Model Addytywny GAM	<i>Temp</i> – temperatura otoczenia, °C <i>Wind</i> – prędkość wiatru, m/s
<i>m05</i>	Uogólniony Model Addytywny GAM	<i>Temp</i> – temperatura otoczenia, °C <i>Wind</i> – prędkość wiatru, m/s <i>Rad</i> – natężenie promieniowania słonecznego, W/m ²
<i>m06</i>	Uogólniony Model Addytywny GAM	<i>Temp</i> – temperatura otoczenia, °C <i>Wind</i> – prędkość wiatru, m/s <i>Rad</i> – natężenie promieniowania słonecznego, W/m ² <i>Hum</i> – wilgotność względna, %
<i>m07</i>	Uogólniony Model Addytywny GAM	<i>Temp</i> – temperatura otoczenia, °C <i>Wind</i> – prędkość wiatru, m/s <i>Rad</i> – natężenie promieniowania słonecznego, W/m ² <i>Hour</i> – godzina doby
<i>m08</i>	Uogólniony Model Addytywny GAM	<i>Temp</i> – temperatura otoczenia, °C <i>Grad_{Temp₀₆}</i> – różnica między temperaturą w godzinie (i), a temperaturą w godzinie (i+6) <i>Wind</i> – prędkość wiatru, m/s <i>Rad</i> – natężenie promieniowania słonecznego, W/m ² <i>Hour</i> – godzina doby
<i>m09</i>	Uogólniony Model Addytywny GAM z korekcją błędów modelem AR	<i>Temp</i> – temperatura otoczenia, °C <i>Grad_{Temp₀₆}</i> – różnica między temperaturą w godzinie (i+6), a temperaturą w godzinie (i) <i>Wind</i> – prędkość wiatru, m/s <i>Rad</i> – natężenie promieniowania słonecznego, W/m ² <i>Hour</i> – godzina doby

$$Q_{m01} = \alpha_{m01}Temp + \beta_{m01} + \varepsilon_{m01} \quad (5.18)$$

$$Q_{m02} = \alpha_{m02} \exp(\beta_{m02}Temp) + \varepsilon_{m02} \quad (5.19)$$

$$Q_{m03} = \alpha_{m03} + s(Temp) + \varepsilon_{m03} \quad (5.20)$$

$$Q_{m04} = \alpha_{m04} + s(Temp) + s(Wind) + \varepsilon_{m04} \quad (5.21)$$

$$Q_{m05} = \alpha_{m05} + s(Temp) + s(Wind) + s(Rad) + \varepsilon_{m05} \quad (5.22)$$

$$Q_{m06} = \alpha_{m06} + s(Temp) + s(Wind) + s(Rad) + s(Hum) + \varepsilon_{m06} \quad (5.23)$$

$$Q_{m07} = \alpha_{m07} + s(Temp) + s(Wind) + s(Rad) + s(Hour) + \varepsilon_{m07} \quad (5.24)$$


$$Q_{m08} = \alpha_{m08} + s(Temp) + s(Grad_{Temp_{06}}) + s(Wind) + s(Rad) + s(Hour) + \varepsilon_{m08} \quad (5.25)$$


$$Q_{m09} = \alpha_{m09} + s(Temp) + s(Grad_{Temp_{06}}) + s(Wind) + s(Rad) + s(Hour) + \varepsilon_{m09,corr} \quad (5.26)$$

Zmienna $Grad_{Temp_{06}}$ została wprowadzona w celu uwzględnienia wpływu warunków atmosferycznych w horyzoncie kilku godzin naprzód, na moc ciepłą oddawaną do sieci ciepłowniczej w aktualnej godzinie. Poziom produkowanej mocy ciepłej jest zróżnicowany w zależności od bieżącej sytuacji związanej z narastaniem lub spadkiem temperatury otoczenia w czasie. Podczas eksploatacji badanego systemu, operatorzy produkcji regulują bieżący poziom mocy ciepłej, na podstawie prognozy temperatury otoczenia na okres najbliższych godzin.


5.3.1 Wyniki prognozowania zapotrzebowania na ciepło

Na poniższych rysunkach (Rys. 5.14 oraz Rys. 5.15) przedstawiono dla wybranego rozmiaru okna treningowego z okresu zimowego (ze stycznia) oraz przejściowego (z kwietnia), uzyskane nieliniowe funkcje wygładzające w modelu $m09$. Zastosowano rozmiar okna wynoszący 12 ostatnich dni. Na wykresach widoczny jest wpływ poszczególnych zmiennych na moc ciepłą. Wraz ze wzrostem temperatury, wartość funkcji wygładzającej zmienną określającą addytywny wpływ temperatury otoczenia maleje (Rys. 5.14a). Gdy wartość zmiennej $Grad_{Temp_{06}}$ rośnie (Rys. 5.14b), to wartości funkcji wygładzającej maleją (co oznacza, że jeśli w przeciągu najbliższych godzin temperatura otoczenia wzrośnie względem aktualnej, to zapotrzebowanie na ciepło maleje). Pod wpływem zwiększania prędkości wiatru, wartości funkcji wygładzającej rosną (Rys. 5.14c) (co przekłada się na zwiększenie mocy ciepłej), a wpływ natężenia promieniowania słonecznego (Rys. 5.14d) jest odwrotny (wraz ze wzrostem nasłonecznienia, poziom mocy jest mniejszy). Funkcja wygładzająca zmienną oznaczającą godzinę w dobie, pozwala na uchwycenie poziomu zmian produkcji mocy ciepłej na przestrzeni doby (Rys. 5.14e). W przypadku gdy zmienna wykroczy poza zakres, który wystąpił w oknie uczącym model (np. gdy w oknie treningowym temperatura otoczenia zawierała się w przedziale od -14°C do 7°C , a prognozowana temperatura w dobie następnej wyniesie 10°C), to wartość funkcji wygładzającej otrzymywana jest poprzez ekstrapolację liniową.





Rys. 5.14. Funkcje wygładzające zmienne uczące model m09 dla wybranego okna treningowego w sezonie zimowym. Funkcja wygładzająca zmienną (a) Temp (b) $\text{Grad}_{\text{Temp}_{06}}$ (c) Wind (d) Rad (e) Hour. Kształt funkcji - linia ciągła, przedział granic ufności 95% - linie przerywane



Rys. 5.15. Funkcje wygładzające zmienne uczące model m09 dla wybranego okna treningowego w sezonie przejściowym. Funkcja wygładzająca zmienną (a) Temp (b) $\text{Grad}_{\text{Temp}_{06}}$ (c) Wind (d) Rad (e) Hour. Kształt funkcji - linia ciągła, przedział granic ufności 95% - linie przerywane

W Tab. 5.4 oraz Tab. 5.5 przedstawiono wskaźniki dopasowania poszczególnych funkcji wygładzających zmienne wejściowe z powyższych wykresów do danych treningowych. Parametr *edf* oznacza określa złożoność wygładzenia funkcji (dla *edf* = 1 otrzymuje się linie prostą). Kolumny z parametrami *F* dotyczą istotności wygładzania. Są to statystyki testowe używane w teście ANOVA. Wynikiem tego testu jest wartość *p-value*. Wartości parametru *F* oraz *p-value* wskazują, że zmienne wejściowe w modelu predykcyjnym istotnie objaśniają model predykcyjny.


Tab. 5.4 Charakterystyka funkcji wygładzających dla wybranego okna treningowego z okresu zimowego (dla modelu *m09*)


Funkcja wygładzająca	edf	F	p-value
<i>s(Temp)</i>	8,13	922,90	< 2e-16
<i>s(Temp_Grad_06)</i>	3,04	7,76	8,86e-06
<i>s(Wind)</i>	4,85	8,83	< 2e-16
<i>s(Rad)</i>	2,62	6,53	< 2e-16
<i>s(Hour)</i>	7,59	45,66	< 2e-16

Tab. 5.5 Charakterystyka funkcji wygładzających dla wybranego okna treningowego z okresu przejściowego (dla modelu *m09*)

Funkcja wygładzająca	edf	F	p-value
<i>s(Temp)</i>	2,28	723,90	< 2e-16
<i>s(Temp_Grad_06)</i>	2,32	8,16	2,90e-05
<i>s(Wind)</i>	2,43	3,93	0,0086
<i>s(Rad)</i>	2,31	9,99	3,92e-06
<i>s(Hour)</i>	6,31	18,14	< 2e-16

Na Rys. 5.16 przedstawiono wartości funkcji autokorelacji odchyleń wskazań modelu *m08* (bez zastosowania metody korekcji błędów - Rys. 5.16a) oraz modelu *m09* (z korekcją modelem autoregresyjnym). Po zastosowaniu modelu autokorelacji, wykresy wskazują na brak autokorelacji dla chwilowych błędów modelu.






Rys. 5.16. Wykres funkcji autokorelacji odchyleń modelu (a) model bez korekcji odchyleń – *m08* (b) model z korekcją odchyleń – *m09*

Na potrzeby oceny dokładności badanych modeli, przeprowadzono symulacje ich działania na danych obejmujących dwa pełne lata kalendarzowe 2021-2022. Analiza była nakierunkowana na wyznaczeniu błędów prognozowania godzinowej mocy cieplnej w horyzoncie doby następnej, a także na analizie wpływu rozmiaru przesuwnego w czasie okna z danymi uczącymi model (zgodnie ze schematem na Rys. 5.13). Wyznaczona została prognoza godzinowej mocy cieplnej dla każdego dnia z badanego okresu czasu, dla dwóch przypadków:

- Prognoza mocy cieplnej została wyznaczona w dobie następnej z użyciem prognozowanych danych pogodowych (obarczonych błędem opisanym w podrozdziale 5.1.1)
- Prognoza mocy cieplnej została wyznaczona w dobie następnej z użyciem faktycznych danych pogodowych (w celu sprawdzenia dokładności modelu na danych pogodowych nieobarczonych błędem).

Na Rys. 5.17 przedstawiono dokładność modeli w zależności od rozmiaru okna uczącego model. Za metrykę oceny dokładności przyjęto błąd średniokwadratowy RMSE (wzór (5.27)), który został obliczony dla wszystkich godzinowych wskazań modeli w badanym okresie czasu (dla wszystkich dni w okresie dwóch lat). Wyniki zaprezentowano w podziale na sezon grzewczy na okres zimowy oraz przejściowy. Analizowano zastosowanie przesuwnego w czasie okna z danymi uczącymi modele wynoszący od 4 do 30 dni. Na wykresach przedstawiono dokładność obliczoną na zbiorze testowym w dobie następnej, dla którego prognozowano moc cieplną uprzednio nauczoną modelem w oparciu o zbiór treningowy (z danymi faktycznymi w zakresie danych pogodowych i wykonanej mocy cieplnej). Z przeprowadzonej analizy wynika, że modele GAM, które uwzględniają wpływ zmiennej określającej godzinę w dobie zapewniają najwyższą dokładność, zarówno w okresie zimowym, jak i przejściowym. Model GAM ze zmienną reprezentującą wilgotność powietrza atmosferycznego (model *m06*), lepiej dopasowuje się do zbioru treningowego, jednak na zbiorze testowym osiąga niższą dokładność w porównaniu do modelu *m07*. Jest to spowodowane relatywnie wysokim błędem prognozowania tej danej pogodowej. W okresie zimowym, rozmiar okna wynoszący 10-14 dni zapewnia uzyskanie

najniższego błędu. W przypadku zwiększenia rozmiaru okna, modele wykazują pogorszoną jakość prognozowania. Dla przypadku sezonu przejściowego, właściwy rozmiar okna jest mniejszy i wynosi 6-8 dni. Z analizy wykresu wynika, że najbardziej dokładny w prognozowaniu okazał się model *m09* (uwzględniający temperaturę otoczenia, prędkość wiatru, nasłonecznienie oraz godzinę doby jako zmienne objaśniające model). Błąd modeli *m07* oraz *m08* jest nieznacznie wyższy (błąd RMSE jest o ok. 0,5 MW wyższy).



Rys. 5.17. Błąd RMSE poszczególnych modeli predykcyjnych w zależności od rozmiaru przesuwającego okna czasowego z danymi uczącymi

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5.27)$$


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5.28)$$

gdzie:

n – liczba obserwacji

y_i – wartość rzeczywista


$\hat{y}_i$ – wartość prognozowana




Rys. 5.18. Błąd MAPE zapotrzebowania na ciepło w miesiącach sezonu grzewczego poszczególnych modeli predykcyjnych w zależności od rozmiaru przesuwającego okna czasowego z danymi uczącymi

Rys. 5.18 przedstawia średniomiesięczne błędy względne dla modeli *m07*, *m08*, *m09* (przy użyciu prognozowanych danych pogodowych w zbiorze testowym). Błąd procentowy jest zwiększony w kwietniu, maju oraz październiku w porównaniu do miesięcy zimowych. Jest to spowodowane większym zróżnicowaniem poziomu mocy cieplnej przy zbliżonych warunkach atmosferycznych oraz zwiększeniem błędów prognozy pogody. Przykładowo średniomiesięczny błąd dla marca wynosi ok. 11%, a dla stycznia 5%. Z analizy wykresu wynika również, że zastosowanie mniejszego rozmiaru okna z danymi uczącymi model w okresie przejściowym, pozwala na osiągnięcie lepszej dokładności w prognozowaniu.

Godzinowe przebiegi wskazań modeli oraz rzeczywistej mocy cieplnej na zasilaniu sieci ciepłowniczej dla wybranych dni z lutego oraz kwietnia przedstawiają wykresy na Rys. 5.19 oraz Rys. 5.20.




Rys. 5.19. Wyniki prognozowania zapotrzebowania na ciepło z użyciem modeli m07, m08, m09 dla wybranych dni z okresu zimowego




Rys. 5.20. Wyniki prognozowania zapotrzebowania na ciepło z użyciem modeli m07, m08, m09 dla wybranych dni z okresu przejściowego


Histogramy błędów procentowych dla modeli m07, m08 i m09 przedstawiają poniższe rysunki. Zaprezentowane wartości dotyczą godzinowych błędów modeli podczas działania modeli na danych obejmujących okres dwóch pełnych lat kalendarzowych 2021-2022. Zdecydowana większość godzinowych błędów zawiera się w przedziale od -10% do +10%. Wykresy prezentują symulacje działania modeli na prognozowanych oraz rzeczywistych danych pogodowych w dobie następnej.



Rys. 5.21. Histogramy godzinowych błędów względnych dla modelu m07 (a) dla rzeczywistych danych pogodowych w dobie następnej (b) dla prognozowanych danych pogodowych w dobie następnej



Rys. 5.22. Histogramy godzinowych błędów względnych dla modelu m08 (a) dla rzeczywistych danych pogodowych w dobie następnej (b) dla prognozowanych danych pogodowych w dobie następnej




Rys. 5.23. Histogramy godzinowych błędów względnych dla modelu m09 (a) dla rzeczywistych danych pogodowych w dobie następnej (b) dla prognozowanych danych pogodowych w dobie następnej

5.4 Model prognozowania zapotrzebowania na ciepło poza sezonem grzewczym


Poza sezonem grzewczym, moc oddawana do sieci ciepłowniczej nie jest przeznaczona na cele grzewcze budynków, w związku z tym poziom mocy nie jest uzależniony od danych pogodowych. Na Rys. 5.24. przedstawiono godzinowy przebieg mocy cieplnej dla tego okresu czasu. Z analizy wykresu wynika, że przebieg zapotrzebowanie na ciepło charakteryzuje się wahaniem sezonowym. Poziom produkowanego ciepła po zakończeniu sezonu grzewczego maleje do stabilnego poziomu dla okresu letniego. Podobnie, w okresie pomiędzy okresem letnim, a początkiem sezonu grzewczego produkcja ciepła w każdym dniu sukcesywnie rośnie. Analizując profil poboru ciepła w skali wybranego tygodnia z lipca (Rys. 5.25), zauważyć można różnice w profilu dobowym, które wynikają głównie z dobowej zmienności zużycia ciepła na potrzeby ciepłej wody użytkowej przez odbiorców końcowych. Zauważalne są piki w godzinach wieczornych i obniżanie produkowanego ciepła w elektrociepłowni podczas nocy.

Przeanalizowano zastosowanie trzech modeli do prognozowania mocy cieplnej na okres poza sezonem grzewczym (równanie (5.29), (5.30) oraz (5.31)), wykorzystujące algorytm GAM. W modelu *m10*, model jest zasilany jedną zmienną *Hour* – oznaczającą godzinę w dobie oraz *Day_Year* – oznaczającą dzień w roku. Zmienna *Day_Year* została wprowadzona w celu uchwycenia trendu związanego ze zwiększaniem dobowej produkcji ciepła przed rozpoczęciem sezonu grzewczego oraz zmniejszaniem dobowej produkcji ciepła tuż po jego zakończeniu. Model *m11* uwzględnia dodatkowo zmienną *Day_Week* reprezentującą dzień tygodnia, która ma na celu uwzględnienie wpływu tygodniowej specyfiki poboru ciepła przez sieć (która

zakłada, że podczas weekendu poziom zapotrzebowanej mocy jest obniżony w stosunku do dni roboczych, jak pokazano na Rys. 5.7 w podrozdziale 5.1). Model $m12$ jest rozszerzeniem modelu $m11$ o korekcję odchyleń modelem autoregresyjnym. Podobnie jak dla modelu na sezon grzewczy, zastosowano metodę przesuwne okna w czasie z danymi uczącymi model z ostatnich dni poprzedzających dzień generowania prognozy.



Rys. 5.24. Przebieg mocy ciepłej poza sezonem grzewczym




Rys. 5.25. Przebieg mocy ciepłej poza sezonem grzewczym podczas wybranego tygodnia

$$Q_{m10} = \alpha_{m10} + s(Hour) + s(Day_Year) + \varepsilon_{m10} \quad (5.29)$$

$$Q_{m11} = \alpha_{m11} + s(Hour) + s(Day_Year) + s(Day_Week) + \varepsilon_{m11} \quad (5.30)$$

$$Q_{m12} = \alpha_{m12} + s(Hour) + s(Day_Year) + s(Day_Week) + \varepsilon_{m12,corr} \quad (5.31)$$

Na Rys. 5.26 przedstawiono dla wybranego okna treningowego, postać funkcji wygładzających w modelu GAM. Zauważalny jest wpływ zmiennej oznaczającej godzinę doby (podczas godzin nocnych wartości funkcji maleją, podczas gdy przed pojawieniem się wieczornego pików wzrastają). Jednocześnie, funkcja wygładzająca zmienną oznaczającą dzień tygodnia ma największą wartość dla środy, a podczas soboty i niedzieli najmniejszą. Zmienna *Day_Year* pozwala na uchwycenie sezonowości na przestrzeni poszczególnych dni analizowanego okresu (narastanie sumarycznej produkcji ciepła w dobie poprzedzające rozpoczęcie sezonu grzewczego).



Rys. 5.26. Funkcje wygładzające zmienne objaśniające w modelu *m12* (a) *Hour* (b) *Day_Week* (c) *Day_Year*. Kształt funkcji - linia ciągła, przedział granic ufności 95% - linie przerywane


W poniższej tabeli (Tab. 5.6) przedstawiono dla wybranego okna treningowego poziom dopasowania modeli do danych treningowych i testowych (w dobie następnej). Został

przeanalizowany wpływ rzędu modelu autoregresyjnego (wzór (5.15)) do korekcji odchyłeń modelu. Z analizy wyników wynika, że rząd modelu $R=1$ w wystarczającym stopniu zapewnia dokładność modelu.

Tab. 5.6 Błąd RMSE modeli $m10$, $m11$ oraz $m12$ (dla różnych wartości rzędu modelu autoregresyjnego)

Model	Błąd RMSE, MWt (zbiór treningowy)	Błąd RMSE, MWt (zbiór testowy)
$m10$	1,01	1,07
$m11$	1,04	1,05
$m12$ i $R = 1$	0,85	1,01
$m12$ i $R = 2$	0,83	1,01
$m12$ i $R = 3$	0,84	1,01
$m12$ i $R = 4$	0,83	1,01
$m12$ i $R = 5$	0,83	1,02


Pozytywny wpływ zastosowania autokorelacji błędów modelu widoczny jest na wykresie funkcji korelacji ACF (Rys. 5.27). Widoczna jest istotna różnica pomiędzy wykresami, a odpowiadającymi im wartościami ACF . Po zastosowaniu modelu autokorelacji w modelu $m12$, wykresy sugerują brak autokorelacji w przypadku błędów chwilowych.




Rys. 5.27. Wykres funkcji autokorelacji odchyłeń modelu (a) model bez korekcji odchyłeń - $m11$ (b) model z korekcją odchyłeń - $m12$

5.4.1 Wyniki prognozowania zapotrzebowania na ciepło


Przeprowadzona została analiza dokładności w horyzoncie doby następnej dla rozważanych modeli na okres poza sezonem grzewczym. Rys. 5.28 przedstawia wyniki analizy wpływu rozmiaru okna treningowego na błąd RMSE. Z analiz wykresu wynika, że model *m12* charakteryzuje się najniższym błędem, zarówno na danych treningowych (wykorzystanych do uczenia modelu) oraz na danych testowych (w dobie nadchodzącej). Zastosowanie okna z danymi uczącymi model wynoszącym 14 dni w modelu *m12* pozwoliło na uzyskanie najniższego poziomu błędu RMSE równego 0,83 MWt dla zbioru treningowego oraz 0,38 MWt dla zbioru testowego. Na kolejnym rysunku (Rys. 5.29) przedstawiono wyniki prognozy w postaci godzinowych wskazań modeli dla trzech wybranych dób z lipca.



Rys. 5.28. Wpływ rozmiaru okna treningowego na błąd RMSE modeli *m10*, *m11*, *m12*




Rys. 5.29. Wynik prognozowania mocy ciepłej przy użyciu modelu *m10*, *m11*, *m12* podczas trzech wybranych dni w roku




Rys. 5.30. Histogram godzinowych odchyłeń modelu $m10$, $m11$, $m12$

Histogram odchyłeń wartości prognozowanej od rzeczywistej dla badanych modeli, w całym analizowanym okresie przedstawia Rys. 5.30. Model $m12$ wykazuje najwięcej wskazań odchyłeń poniżej 1 MWt. Analizując statystykę błędu względnego modelu $m12$ (Rys. 5.31) w poszczególnych godzinach doby, zauważyć można, że największy poziom fluktuacji błędu pojawia się w godzinie 7:00 oraz 19:00. W tych godzinach następują największe wahania mocy cieplnej oddawanej do sieci ciepłowniczej w związku z pikiem porannym oraz wieczornym, co utrudnia dokładne prognozowanie. Na przestrzeni doby, błędy względne są rozrzucone w zakresie od ok. -5% do 5%. Średniomiesięczne błędy MAPE modeli w poszczególnych miesiącach, przedstawia Rys. 5.32.

Z przeprowadzonych analiz wynika, że model $m12$ będący modelem autoregresyjnym z oknem treningowym równym 14 dni, pozwala na uzyskanie najmniejszego błędu. W analizowanych modelach oprócz godziny doby uwzględniono także dzień roku i dzień tygodnia, co wyraźnie wpłynęło na zwiększenie dokładności uzyskiwanych prognoz w dobie następnej.



Rys. 5.31. Rozkład błędu procentowego modelu m12 w podziale na godziny doby



Rys. 5.32. Średniomiesięczny błąd MAPE w poszczególnych miesiącach okresu poza sezonem grzewczym

6 Modelowanie pracy turbiny gazowej z kotłem odzysknicowym

Model do symulacji pracy układu turbiny gazowej z odzyskiem ciepła w wodnym kotle odzysknicowym został opracowany z wykorzystaniem komercyjnego oprogramowania Epsilon Professional. Oprogramowanie to znalazło zastosowanie w projektowaniu, optymalizacji i ocenie procesów termodynamicznych i okazało się niezawodnym narzędziem w procesie modelowania układów cieplnych elektrociepłowni [106] [107]. Model symulacyjny stanowi integralną część opracowanego w ramach niniejszej rozprawy narzędzia do planowania pracy badanej elektrociepłowni i służy do obliczeń parametrów produkcyjnych badanego układu wytwarzania ciepła w kogeneracji. Kluczowymi parametrami są produkowana moc elektryczna, moc cieplna i zużycie paliwa gazowego w zakładanym horyzoncie czasowym. W kolejnych podrozdziałach przedstawiono sposób budowy modelu obliczeniowego wraz z opracowaną metodą, wykorzystującą zaawansowane algorytmy analizy danych, do kalibracji wyników modelowania na podstawie rzeczywistych danych procesowych. Kalibracja modelu ma umożliwić poprawę dokładności prognozowania wymaganych z punktu widzenia planowania pracy elektrociepłowni wskaźników.

6.1 Model turbiny gazowej i kotła odzysknicowego

Model turbiny gazowej bazuje na wykorzystaniu uproszczonego modelu opartego o krzywe korekcyjne pochodzące od producenta urządzenia. W Tab. 6.1 przedstawiono dane wyliczane z krzywych korekcyjnych. Moc elektryczna netto (po odjęciu potrzeb własnych), jednostkowe zużycie energii chemicznej paliwa, masowy przepływ oraz temperatura spalin wylotowych są obliczane za pomocą interpolacji liniowej pomiędzy charakterystycznymi punktami w funkcji parametrów wymienionych w Tab. 6.2. Jednostkowe zużycie energii chemicznej paliwa określa stosunek pomiędzy zużyciem mocy cieplnej w paliwie do jednostkowej produkcji energii elektrycznej dla turbiny. Krzywe korekcyjne parametrów turbiny GE LM6000-PF w funkcji danych wejściowych zostały przedstawione na Rys. 6.1 do Rys. 6.8. Z wykresów odczytywane są wartości poszczególnych współczynników krzywych, które pozwalają na obliczenie parametrów produkcyjnych zgodnie z wzorami od (6.1) do (6.4).

Analizując wykresy z krzywymi korekcyjnymi, zauważyć można, że zmiany temperatury otoczenia dolotowego do sprężarki, mają największy wpływ na poziom zmian produkowanej mocy elektrycznej. Przy pełnym obciążeniu turbiny, zmiana temperatury o 1 °C, powoduje spadek mocy elektrycznej o około 0,5 MW. Jest to spowodowane spadkiem gęstości powietrza wraz ze wzrostem jego temperatury, co powoduje że przez turbinę przepływa mniejszy przepływ masowy [108]. Wzrostowi temperatury powietrza towarzyszy również wzrost zużycia jednostkowego energii chemicznej paliwa, na skutek pogorszenia sprawności sprężarki. Przykładowo, dla temperatury powietrza równej 0 °C, przepływ i temperatura spalin wynosi

odpowiednio 125 kg/s i 440 °C. Dla temperatury powietrza 30 °C, parametry te wynoszą 105 kg/s i 470 °C. Pozostałe dane (ciśnienie otoczenia, spadek ciśnienia powietrza dolotowego i spalin) wpływają w mniejszym stopniu na parametry pracy turbiny.

Tab. 6.1 Dane wyliczane z krzywych korekcyjnych turbiny gazowej

Oznaczenie	Symbol	Jednostka
Moc elektryczna netto	N_{el}	MW
Jednostkowe zużycie energii chemicznej paliwa	HR	kJ/kWh
Przepływ spalin	$\dot{m}_3$	kg/s
Temperatura spalin	T_3	°C

Tab. 6.2 Dane wejściowe do krzywych korekcyjnych turbiny gazowej

Oznaczenie	Symbol	Jednostka
Temperatura powietrza wlotowa do sprężarki	T_1	°C
Ciśnienie otoczenia	p_0	bar
Spadek ciśnienia powietrza wlotowego (różnica między ciśnieniem otoczenia, a ciśnieniem na wlocie do sprężarki)	$\Delta p_{pow} = p_0 - p_1$	mbar
Spadek ciśnienia spalin wylotowych (różnica między ciśnieniem na wylocie z turbiny, a ciśnieniem otoczenia)	$\Delta p_{sp} = p_3 - p_0$	mbar
Wilgotność względna powietrza	φ_1	%
Obciążenie turbiny	$LOAD$	%

$$N_{el} = N_{el,nom} \cdot \left(N_{el}^{T_1} \cdot N_{el}^{p_0} \cdot N_{el}^{\Delta p_{pow}} \cdot N_{el}^{\Delta p_{sp}} \cdot N_{el}^{\varphi_1} \cdot N_{el}^{LOAD} \right) \quad (6.1)$$

$$HR = HR_{nom} \cdot \left(HR^{T_1} \cdot HR^{p_0} \cdot HR^{\Delta p_{pow}} \cdot HR^{\Delta p_{sp}} \cdot HR^{\varphi_1} \cdot HR^{LOAD} \right) \quad (6.2)$$

$$\dot{m}_3 = \dot{m}_{3,nom} \cdot \left(\dot{m}_3^{T_1} \cdot \dot{m}_3^{p_0} \cdot \dot{m}_3^{\Delta p_{pow}} \cdot \dot{m}_3^{\Delta p_{sp}} \cdot \dot{m}_3^{\varphi_1} \cdot \dot{m}_3^{LOAD} \right) \quad (6.3)$$

$$T_3 = T_{3,nom} + \left(T_3^{T_1} + T_3^{p_0} + T_3^{\Delta p_{pow}} + T_3^{\Delta p_{sp}} + T_3^{\varphi_1} + T_3^{LOAD} \right) \quad (6.4)$$

gdzie:


indeks dolny *nom* – odnosi się do warunków odniesienia w warunkach ISO (temperatura = 15 °C, ciśnienie = 101 325 Pa, wilgotność względna = 60%). Wartości parametrów produkcyjnych dla badanej turbiny w warunkach ISO przedstawia Tab. 6.3.

X^p – współczynnik krzywej korekcyjnej parametru produkcyjnego X (mocy elektrycznej N_{el} , jednostkowego zużycia energii chemicznej paliwa HR , masowego przepływu spalin $\dot{m}_3$, temperatury spalin T_3) w funkcji danej wejściowej p (temperatury powietrza dolotowego T_1 , ciśnienia atmosferycznego p_0 , spadku


ciśnienia powietrza Δp_{pow} , spadku ciśnienia spalin Δp_{sp} , wilgotności względnej powietrza dolotowego φ_1 , obciążenia $LOAD$).

Tab. 6.3 Parametry produkcyjne turbiny GE LM6000-PF w warunkach ISO


Symbol	Wartość	Jednostka
$N_{el,nom}$	42,14	MW
HR_{nom}	8875,00	kJ/kWh
$\dot{m}_{3,nom}$	125,16	kg/s
$T_{3,nom}$	463,10	°C




Rys. 6.1 Krzywe korekcyjne parametrów $N_{el}^{T_1}$ (moc elektryczna), HR^{T_1} (jedn. zużycie en. chem. paliwa), $\dot{m}_3^{T_1}$ (przepływ spalin), $T_3^{T_1}$ (temperatura spalin) w funkcji temperatury powietrza dolotowego T_1




Rys. 6.2 Krzywe korekcyjne parametrów $N_{el}^{p_0}$ (moc elektryczna), HR^{p_0} (jedn. zużycie en. chem. paliwa), $\dot{m}_3^{p_0}$ (przepływ spalin), $T_3^{p_0}$ (temperatura spalin) w funkcji ciśnienia otoczenia p_0




Rys. 6.3 Krzywe korekcyjne parametrów $N_{el}^{\Delta p_{pow}}$ (moc elektryczna), $HR^{\Delta p_{pow}}$ (jedn. zużycie en. chem. paliwa), $\dot{m}_3^{\Delta p_{pow}}$ (przepływ spalin), $T_3^{\Delta p_{pow}}$ (temperatura spalin) w funkcji spadku ciśnienia powietrza dolotowego Δp_{pow}




Rys. 6.4 Krzywe korekcyjne parametrów $N_{el}^{\Delta p_{sp}}$ (moc elektryczna), $\dot{m}_3^{\Delta p_{sp}}$ (przepływ spalin), $T_3^{\Delta p_{sp}}$ (temperatura spalin) w funkcji spadku ciśnienia spalin Δp_{sp}




Rys. 6.5 Krzywe korekcyjne parametru $N_{el}^{\varphi_1}$ (moc elektryczna) w funkcji temperatury T_1 oraz wilgotności φ_1 powietrza dolotowego



Rys. 6.6 Krzywe korekcyjne parametru HR^{φ_1} (jedn. zuż. en. chem. paliwa) w funkcji temperatury T_1 oraz wilgotności φ_1 powietrza dolotowego



Rys. 6.7 Krzywe korekcyjne parametru $\dot{m}_3^{\varphi_1}$ (przepływ spalin) w funkcji temperatury T_1 oraz wilgotności φ_1 powietrza dolotowego



Rys. 6.8 Krzywe korekcyjne parametru $T_3^{\varphi_1}$ (temperatura spalin) w funkcji temperatury T_1 oraz wilgotności φ_1 powietrza dolotowego

Na Rys. 6.9 przedstawiono schemat przepływowy analizowanego układu turbiny gazowej i wodnego kotła odzysknicowego. Turbina gazowa jest wyposażona w układ podgrzewu powietrza dolotowego do sprężarki powietrza (układ anti-oblodzeniowy). Układ ma na celu ochronę przed oblodzeniem łopatek kompresora i jest

wykorzystywane głównie podczas okresu zimowego. Podczas pracy turbiny, powietrze jest podgrzewane na wymienniku ciepła zasilanym gorącą wodą. Logika sterowania pracy układu jest oparta o pomiar temperatury otoczenia T_0 oraz wilgotności względnej powietrza φ_0 przed wymiennikiem ciepła. Tab. 6.4 określa wartość temperatury T_1 za układem anty-oblodzeniowym w zależności od parametrów powietrza wlotowego. Podgrzanie powietrza do wymaganej temperatury uzyskiwane jest poprzez sterowanie poziomem przepływu gorącej wody. Jeżeli warunki w Tab. 6.4 nie są spełnione, wówczas układ podgrzewu powietrza nie pracuje.

Tab. 6.4 Wartość temperatury powietrza dolotowego do turbiny T_1 za układem anty-oblodzeniowym w zależności od wartości temperatury T_0 i wilgotności powietrza φ_0

Temperatura powietrza po podgrzaniu	Kryterium
$T_1 = T_0 + 5,6 \text{ }^{\circ}\text{C}$	$(T_0 \leq -17,7 \text{ }^{\circ}\text{C}) \text{ oraz } (\varphi_0 \geq 64\%)$
$T_1 = 4,4 \text{ }^{\circ}\text{C}$	$(T_0 \leq 4,4 \text{ }^{\circ}\text{C}) \text{ oraz } (\varphi_0 \geq 0,0186T_0^2 + 0,7414T_0 + 71,33 \text{ \%}) \text{ oraz } (T_0 + 5,6 \text{ }^{\circ}\text{C}) \geq 4,4 \text{ }^{\circ}\text{C}$
$T_1 = T_0 + 5,6 \text{ }^{\circ}\text{C}$	$(T_0 \leq 4,4 \text{ }^{\circ}\text{C}) \text{ oraz } (\varphi_0 \geq 0,0186T_0^2 + 0,7414T_0 + 71,33 \text{ \%}) \text{ oraz } (T_0 + 5,6 \text{ }^{\circ}\text{C}) < 4,4 \text{ }^{\circ}\text{C}$

Układ podgrzewu gazu ma na celu utrzymywanie stałej temperatury paliwa na wlocie do komory spalania turbiny (na poziomie $119 \text{ }^{\circ}\text{C}$) oraz palnika dopalającego spaliny (na poziomie $38 \text{ }^{\circ}\text{C}$). Podobnie jak układ anty-oblodzeniowy, wymiennik do podgrzewu gazu jest zasilany gorącą wodą (z obiegu potrzeb własnych obiektu).

Wyniki z modelu krzywych korekcyjnych turbiny są wykorzystywane do przeprowadzenia obliczeń dotyczących pracy kotła odzysknicowego, które oparte są o równania fizyczne, zgodnie z zasadami zachowania masy i energii, zgodnie z opisanym w dalszej części rozdziału tokiem obliczeń.

Wyznaczony z krzywych korekcyjnych masowy przepływ spalin na wylocie z turbiny jest daną wejściową w bilansie masowym (równanie (6.5)), z którego wyznaczany jest przepływ powietrza dolotowego. Przepływ masowy paliwa gazowego do komory spalania turbiny wyznaczany jest na podstawie równania (6.6).

$$\dot{m}_1 = \dot{m}_3 - \dot{m}_2 \quad (6.5)$$

gdzie:

$\dot{m}_1$ – masowy przepływ powietrza, kg/s

$\dot{m}_2$ – masowy przepływ paliwa gazowego, kg/s

$\dot{m}_3$ – masowy przepływ spalin, kg/s


$$\dot{m}_2 = \frac{N_{el}}{\frac{3600}{HR * NCV}} \quad (6.6)$$

gdzie:

N_{el} – moc elektryczna (z krzywych korekcyjnych), kJ/s

NCV – wartość opałowa paliwa gazowego (obliczana na podstawie składu paliwa), kJ/kg

HR – jednostkowe zużycie energii chemicznej paliwa (z krzywych korekcyjnych), kJ/kWh



Rys. 6.9 Schemat przepływowy turbiny gazowej i wodnego kotła odzysknicowego. (1) – powietrze dolotowe do sprężarki (2) – paliwo gazowe do komory spalania (3) – spaliny wylotowe z turbiny (4) – paliwo gazowe do palnika dopalającego spaliny (5) – spaliny dolotowe do kotła odzysknicowego (6) – woda sieciowa na wlocie do kotła (7) – woda sieciowa na wylocie z kotła (8) – spaliny na wlocie do komina

Moc cieplna palnika dopalającego spaliny $\dot{Q}_{SF}$ jest obliczana zgodnie ze wzorem (6.7). Poziom przepływu gazu ziemnego do palnika jest regulowany w celu zwiększenia mocy cieplowniczego kotła do wymaganego poziomu.

$$\dot{Q}_{SF} = \dot{Q}_4 + \dot{m}_4 \cdot NCV \quad (6.7)$$

gdzie:

$\dot{Q}_4$ – ciepło jawne paliwa gazowego, kJ/s

$\dot{m}_4$ – masowy przepływ paliwa gazowego do palnika dopalającego spaliny, kg/s

Na podstawie bilansu masowego (wzór (6.8)) palnika dopalającego spaliny, możliwe jest obliczenie masowego przepływu spalin za palnikiem $\dot{m}_5$ (na wlocie do kotła odzysknicowego), na podstawie obliczonego przepływu gazu do palnika oraz przepływu spalin wylotowych z turbiny (otrzymanego z modelu krzywych korekcyjnych).

$$\dot{m}_5 = \dot{m}_3 + \dot{m}_4 \quad (6.8)$$

Wodny kocioł odzysknicowy zamodelowano jako przeciwprądowy wymiennik ciepła spaliny/woda. Modelowanie odbywa się za pomocą nieliniowego układu równań, który rozwiązuje się iteracyjnie w celu obliczenia pozostałych nieznanymi parametrów. Zmiennymi układu równań są przepływ masowy, ciśnienie i entalpia właściwa [109]. Moc kotła odzysknicowego $\dot{Q}_{HRHWP}$ obliczana jest na podstawie bilansu zachowania energii, zgodnie z wzorem (6.9):

$$\dot{Q}_{HRHWP} = (kA)LMTD = \dot{m}_5(h_5 - h_8) = \dot{m}_6(h_7 - h_6) \quad (6.9)$$

gdzie:

(kA) – całkowity współczynnik przenikania ciepła, kW/K

$LMTD$ – średnia logarytmiczna różnica temperatur, -

h_5 – entalpia właściwa spalin wlotowych do kotła, kJ/kg

h_8 – entalpia właściwa spalin wylotowych z kotła, kJ/kg

h_6 – entalpia właściwa wody wlotowej do kotła, kJ/kg

h_7 – entalpia właściwa wody wylotowej z kotła, kJ/kg

Entalpię w równaniu (6.9) oblicza się z tablic termodynamicznych przy zachowaniu założenia gazu doskonałego, jako funkcję stanu temperatury i ciśnienia biorąc pod uwagę udziały molowe poszczególnych składników spalin. Skład spalin obliczany był w oparciu o obliczenia stechiometryczne uwzględniające skład powietrza i paliwa gazowego. Podczas pracy kotła, część wody gorącej zza kotła trafia do obiegu recyrkulacji w celu zapewnienia stałej temperatury dolotowej do kotła na poziomie 60

°C. Przepływ wody sieciowej przepływający przez kocioł jest regulowany w celu osiągnięcia temperatury wylotowej z kotła równej 135 °C.

Średnia logarytmiczna różnica temperatur obliczana jest dla wymiennika przeciwprądowego, zgodnie z poniższą zależnością.

$$LMTD = \frac{(T_5 - T_7) - (T_8 - T_6)}{\ln \left(\frac{T_5 - T_7}{T_8 - T_6} \right)} \quad (6.10)$$

gdzie:

T_5 – temperatura spalin wlotowych do kotła, °C

T_8 – temperatura spalin wylotowych z kotła, °C

T_6 – temperatura wody wlotowej do kotła, °C

T_7 – temperatura wody wylotowej z kotła, °C

Wykaz wymaganych danych wejściowych do opracowanego modelu obliczeniowego układu turbiny gazowej z wodnym kotłem odzysknicowym zawarto w Tab. 6.5.

Tab. 6.5 Dane wejściowe do modelu obliczeniowego

Lp.	Dana wejściowa do modelu obliczeniowego	Symbol	Jednostka
1	Temperatura powietrza przed filtrem powietrza	T_0	°C
2	Ciśnienie atmosferyczne	p_0	kPa
3	Wilgotność względna powietrza na wlocie do filtra powietrza	φ_0	%
4	Ciśnienie spalin wylotowych z turbiny gazowej	p_3	kPa
5	Udział molowy tlenu w spalinach wylotowych	O_{2ref}	vol. %
6	Temperatura paliwa gazowego na wlocie do komory spalania	T_2	°C
7	Ciśnienie paliwa gazowego na wlocie do komory spalania	p_2	kPa
8	Obciążenie turbiny gazowej	$LOAD$	%
9	Temperatura paliwa gazowego na wlocie do palnika dopalającego spaliny	T_4	°C
10	Ciśnienie paliwa gazowego na wlocie do palnika dopalającego spaliny	p_4	kPa
11	Przepływ paliwa gazowego do palnika dopalającego spaliny	$\dot{m}_4$	kg/s
12	Temperatura wody wlotowej do kotła odzysknicowego	T_6	°C
13	Temperatura wody wylotowej z kotła odzysknicowego	T_7	°C
14	Całkowity współczynnik wnikania ciepła kotła odzysknicowego	(kA)	kW/K
15	Skład chemiczny powietrza	N_2, O_2, Ar, CO_2	vol. %
16	Skład chemiczny paliwa gazowego	$CH_4, C_2H_6, C_3H_8, C_4H_{10}, N_2, CO_2$	vol. %

6.1.1 Metoda kalibracji modelu turbiny gazowej w oparciu o dane ruchowe

W celu zwiększenia dokładności obliczeń modelu symulacyjnego, opracowano metodę kalibracji modelu, na podstawie analizy danych ruchowych pochodzących z eksploatacji. Metoda opiera się na wprowadzeniu współczynników poprawkowych dla wartości wyznaczanych z modelu krzywych korekcyjnych. Współczynniki obliczane są w oparciu o rzeczywiste dane ruchowe i dotyczą mocy elektrycznej (wzór 6.11), jednostkowego zużycia energii chemicznej paliwa (wzór 6.12), masowego przepływu spalin (wzór 6.13) oraz temperatury spalin na wylocie z turbiny gazowej (wzór 6.14). Współczynniki obliczane są jako stosunek rzeczywistej wartości do wartości obliczonej (w przypadku mocy elektrycznej, jednostkowego współczynnika zużycia energii chemicznej paliwa oraz przepływu spalin). Dla temperatury spalin wylotowych, współczynnik poprawkowy jest obliczany jako różnica pomiędzy rzeczywistą, a obliczaną wartością.

$$CF_{N_{el}} = \frac{N_{el,real}}{N_{el}} \quad (6.11)$$

$$CF_{HR} = \frac{HR_{real}}{HR} \quad (6.12)$$

$$CF_{\dot{m}_3} = \frac{\dot{m}_{3,real}}{\dot{m}_3} \quad (6.13)$$

$$CO_{T_3} = T_{3,real} - T_3 \quad (6.14)$$

Rzeczywista moc elektryczna oraz rzeczywista temperatura spalin jest bezpośrednio mierzona przez układy pomiarowe, tak więc współczynniki poprawkowe dla tych parametrów można wprost wyliczyć. Jednostkowe zużycie energii chemicznej paliwa oraz masowy przepływ spalin może być obliczony na podstawie pomiaru przepływu gazu oraz mocy elektrycznej turbiny, zgodnie z przedstawionym w dalszej części tokiem. Wzór (6.15) służy do obliczenia jednostkowego zużycia energii chemicznej paliwa HR .

$$HR = \frac{3600 \cdot NCV \cdot \dot{m}_2}{N_{el}}, kJ/kWh \quad (6.15)$$

gdzie:

$\dot{m}_2$ – przepływ masowy gazu, kg/s

N_{el} – moc elektryczna (z krzywych korekcyjnych), kJ/s

NCV – wartość opałowa paliwa gazowego (obliczana na podstawie składu paliwa), kJ/kg

Wartość opałową paliwa gazowego NCV wyznaczano na podstawie pomiaru składu spalanego paliwa, zgodnie z poniższą zależnością (6.16). Skład spalanego paliwa przedstawia Tab. 6.6.

$$NCV = \frac{\sum_{i=1}^n NCV_i z_i}{M_g}, MJ/kg \quad (6.16)$$

$$M_g = \sum_{i=1}^n M_{g,i} z_i, kg/kmol \quad (6.17)$$

gdzie:

NCV_i – wartość opałowa składnika i w paliwie gazowym, MJ/kmol

z_i – zawartość składnika i w paliwie gazowym, kmol/kmol

M_g – masa molowa gazu, kg/kmol

$M_{g,i}$ – masa molowa składnika i w paliwie gazowym, kg/kmol

Tab. 6.6 Skład paliwa gazowego

Składnik	Udział molowy $z_{i,r}$
Metan (CH_4)	0,9591
Etan (C_2H_6)	0,0281
Azot (N_2)	0,0054
Siarkowodór (H_2S)	0,0030
Propan (C_3H_8)	0,0025
Dwutlenek węgla (CO_2)	0,0015
n-Butan (C_4H_{10})	0,0004

Wzór (6.18) przedstawia zależność na obliczenie masowego przepływu spalin, na podstawie pomiaru przepływu paliwa gazowego i obliczeń składu i ilości spalin. Liczbę moli spalin oraz skład gazu (udział molowych składników) odniesiony jest do jednostki suchego paliwa gazowego (kmol). Skład spalin został obliczony na podstawie bilansu substancji doprowadzanych (powietrze oraz gaz ziemny) i wyprowadzanych z komory spalania (spaliny), przy założeniu spalania zupełnego i całkowitego [110]. Kolejne zależności od (6.20) do (6.36), prowadzą do wyznaczenia liczby moli spalin mokrych, niezbędnych do wyliczenia rzeczywistego masowego przepływu spalin.

$$\dot{m}_3 = \frac{M_s n_s'' \dot{m}_2}{M_g}, kg/s \quad (6.18)$$

$$M_s = \sum_{i=1}^n M_{s,i} z_{s,i}, kg/kmol \quad (6.19)$$

gdzie:

$\dot{m}_2$ – przepływ masowy paliwa gazowego, kg/s

M_s – masa molowa spalin mokrych, kg/kmol

n_s'' – liczba moli spalin mokrych, kmol/j.p.

$z_{s,i}$ – zawartość składnika i w spalinach, kmol/kmol

$M_{s,i}$ – masa molowa składnika i w spalinach, kg/kmol

Ilość substancji poszczególnych pierwiastków w jednostce paliwa gazowego obliczono na podstawie wzorów (6.20) - (6.23), bazując na danych pomiarowych udziału molowego każdego ze składnika w paliwie gazowym. W równaniach zastosowano ogólny symbol węglowodorów C_mH_n . Poza zawartością metanu, mierzono również udział etanu, propanu, butanu, izobutanu, pentanu oraz izopentanu.

$$n'_C = CH_4 + mC_mH_n + CO_2, \text{ kmol C/j. p.} \quad (6.20)$$

$$n'_{H_2} = H_2 + 2CH_4 + \frac{1}{2}nC_mH_n, \text{ kmol } H_2/\text{j. p.} \quad (6.21)$$

$$n'_{O_2} = CO_2, \text{ kmol } O_2/\text{j. p.} \quad (6.22)$$

$$n'_{N_2} = N_2, \text{ kmol } N_2/\text{j. p.} \quad (6.23)$$

gdzie:

j.p. – jednostka paliwa

Teoretyczna ilość powietrza atmosferycznego, koniecznego do doprowadzenia do komory spalania, została obliczona zgodnie ze wzorem (6.24), wykorzystując zależność (6.25) na ilość teoretycznego tlenu do spalania. Wzór (6.26) posłużył do obliczenia współczynnika nadmiaru powietrza λ , gdzie $O_{2,spaliny}$ oznacza zawartość tlenu (udział molowy) w spalinach wylotowych. Podczas pracy turbiny wartość ta jest utrzymywana na poziomie 15% i jest regulowana poprzez kontrolowanie doprowadzanego przepływu objętościowego powietrza.

$$n_{a \min} = \frac{1}{0.21} n_{o \min}, \text{ kmol/j. p.} \quad (6.24)$$

$$n_{o \min} = n'_C + \frac{1}{2}n'_{H_2} - n'_{O_2}, \text{ kmol/j. p.} \quad (6.25)$$

$$\lambda = \frac{21}{21 - O_{2,spaliny}} = \frac{n'_a}{n_{a \min}}, \text{ kmol/j. p.} \quad (6.26)$$

Ilość substancji składników spalin po spaleniu jednostki paliwa wyznaczono na podstawie wzorów (6.27) - (6.32). Wyraz $X_{za}n'_a$ oznacza wilgoć pochodzącą z powietrza, gdzie molowy stopień zwilżenia powietrza X_{za} obliczono zgodnie ze wzorem (6.31). Wilgotność względną odpowiadającą ciśnieniu saturacji dla danej temperatury powietrza oznaczono przez $\varphi_{p_{sat}}$.

$$n''_{CO_2} = n'_C, \text{ kmol/j. p.} \quad (6.27)$$

$$n''_{O_2} = 0.21(\lambda - 1)n_{a\min}, \text{ kmol/j. p.} \quad (6.28)$$


$$n''_{N_2} = n'_{N_2} + 0.79n'_a, \text{ kmol/j. p.} \quad (6.29)$$

$$n''_{H_2O} = n'_{H_2} + X_{za}n'_a, \text{ kmol/j. p.} \quad (6.30)$$


$$X_{za} = \frac{\varphi_{p_{sat}}}{p_a - \varphi_{p_{sat}}}, \text{ kmol H}_2\text{O/kmol powietrza} \quad (6.31)$$

$$n''_s = n''_{CO_2} + n''_{N_2} + n''_{O_2} + n''_{H_2O}, \text{ kmol/j. p.} \quad (6.32)$$


Na podstawie powyżej przedstawionej metodyki, zostały obliczone współczynniki korekcyjne dla jednej z turbin gazowych na podstawie analizy danych godzinowych za okres dwóch pełnych lat kalendarzowych 2021-2022. Na Rys. 6.10, Rys. 6.11, Rys. 6.12 oraz Rys. 6.13 zostały przedstawione wykresy rozrzutu pomiędzy współczynnikami poprawkowymi, a wartościami temperatury powietrza dolotowego do sprężarki T_1 (za filtrem powietrza i układem anti-icing). Z analizy wykresów wynika, że wyniki otrzymane z wykorzystaniem krzywych korekcyjnych pochodzących od producenta turbiny wykazują rozbieżności z wynikami zarejestrowanymi w trakcie eksploatacji. Dla przykładu, wartość współczynnika poprawkowego mocy elektrycznej CF_{Nel} od temperatury T_1 zawierała się w przedziale od ok. 0,9 do 1,10, co odpowiada błędowi względnemu na poziomie ok. 10%.




Rys. 6.10 Współczynnik poprawkowy mocy elektrycznej CF_{Nel} w zależności od temperatury powietrza dolotowego T_1




Rys. 6.11 Współczynnik poprawkowy masowego przepływu spalin CF_{m_3} w zależności od temperatury powietrza dolotowego T_1



Rys. 6.12 Współczynnik poprawkowy jednostkowego zużycia energii chemicznej paliwa CF_{HR} w zależności od temperatury powietrza dolotowego T_1




Rys. 6.13 Współczynnik poprawkowy temperatury spalin CO_{T_3} w zależności od temperatury powietrza dolotowego T_1




Rys. 6.14 Różnica ciśnienia pomiędzy ciśnieniem spalin z turbiny a ciśnieniem atmosferycznym w zależności od temperatury powietrza dolotowego T_1

Daną wejściową do modelu obliczeniowego układu turbiny gazowej z kotłem odzysknicowym jest spadek ciśnienia spalin wylotowych oraz całkowity współczynnik przenikania ciepła kotła odzysknicowego. W celu zaprognozowania parametrów pracy badanego układu do wytwarzania energii elektrycznej i ciepła, konieczna jest również prognoza tych danych. Rzeczywiste wartości spadku ciśnienia spalin w zależności od temperatury powietrza dolotowego obrazuje wykres na Rys. 6.14. Na Rys. 6.15 oraz Rys. 6.16 przedstawiono odpowiednio zależność rzeczywistych wartości współczynnika (k_A) od temperatury powietrza dolotowego do turbiny (który determinuje poziom

przepływu i temperatury spalin wylotowych) oraz zależność od mocy palnika zwiększającego entalpię spalin zasilających kocioł. Im większa moc palnika dopalającego, tym całkowity współczynnik przenikania ciepła kotła jest większy. Rzeczywista wartość współczynnika (kA) była obliczana na podstawie rzeczywistej mocy cieplnej przekazywanej do wody sieciowej oraz pomiaru temperatur wody oraz spalin na dolocie i wylocie z kotła, zgodnie ze wzorami (6.9) oraz (6.10).



Rys. 6.15 Całkowity współczynnik wnikania ciepła kotła odzysknicowego w zależności od temperatury powietrza dolotowego T_1



Rys. 6.16 Całkowity współczynnik wnikania ciepła kotła odzysknicowego w zależności od mocy palnika dopalającego spaliny

Analizując powyższe wykresy, zauważyć można duży rozrzut wartości dla tych samych wartości temperatur powietrza dolotowego. W celu zwiększenia dokładności prognoz współczynników w dobie następnej, uzasadnione jest zbudowanie modelu w oparciu o dodatkową zmienną. Jak wynika z krzywych korekcyjnych turbiny, największy wpływ na parametry produkcyjne, poza temperaturą powietrza dolotowego ma ciśnienie atmosferyczne. W Tab. 6.7 i Tab. 6.8. przedstawiono wartości współczynników korelacji Pearson'a i Spearman'a obliczone na danych z powyższych wykresów, pomiędzy współczynnikami poprawkowymi i spadku ciśnienia spalin, a temperaturą powietrza dolotowego oraz ciśnienia atmosferycznego. Wskaźniki korelacji dla całkowitego współczynnika przenikania ciepła kotłów odzysknicowych przedstawiono w Tab. 6.9 i Tab. 6.10. Dla współczynnika (kA) została dodatkowo oceniona korelacja pomiędzy mocą cieplną palnika dopalającego spaliny $\dot{Q}_{SF}$.

Tab. 6.7 Współczynniki korelacji Pearson'a i Spearman'a dla współczynników poprawkowych i spadku ciśnienia spalin (Turbina GT1)

	T_1		p_0	
	Współczynnik Pearson'a	Współczynnik Spearman'a	Współczynnik Pearson'a	Współczynnik Spearman'a
$CF_{N_{el}}$	0,27	0,11	-0,07	-0,14
$CF_{\dot{m}_3}$	0,05	-0,08	0,04	0,03
CF_{HR}	-0,43	-0,40	0,24	0,30
CO_{T_3}	0,43	0,52	-0,03	-0,05
ΔP_{sp}	-0,94	-0,90	0,10	0,12

Tab. 6.8 Współczynniki korelacji Pearson'a i Spearman'a dla współczynników poprawkowych i spadku ciśnienia spalin (Turbina GT2)

	T_1		p_0	
	Współczynnik Pearson'a	Współczynnik Spearman'a	Współczynnik Pearson'a	Współczynnik Spearman'a
$CF_{N_{el}}$	0,55	0,35	-0,04	-0,05
$CF_{\dot{m}_3}$	0,36	0,15	0,03	0,07
CF_{HR}	-0,49	-0,55	0,13	0,25
CO_{T_3}	0,29	0,33	-0,01	0,01
ΔP_{sp}	-0,95	-0,90	0,10	0,12

Tab. 6.9 Współczynniki korelacji Pearson'a i Spearman'a dla całkowitego współczynnika przenikania ciepła (dla kotła HRHWP1)

	T_1		p_0		$\dot{Q}_{SF}$	
	Współczynnik Pearson'a	Współczynnik Spearman'a	Współczynnik Pearson'a	Współczynnik Spearman'a	Współczynnik Pearson'a	Współczynnik Spearman'a
(kA)	-0,77	-0,82	0,12	0,11	0,79	0,78

Tab. 6.10 Współczynniki korelacji Pearson'a i Spearman'a dla całkowitego współczynnika przenikania ciepła (dla kotła HRHWP2)

	T_1		p_0		$\dot{Q}_{SF}$	
	Współczynnik Pearson'a	Współczynnik Spearman'a	Współczynnik Pearson'a	Współczynnik Spearman'a	Współczynnik Pearson'a	Współczynnik Spearman'a
(kA)	-0,56	-0,82	-0,07	0,12	0,79	0,79

6.2 Prognozowanie pracy turbiny gazowej i kotła odzysknicowego

Opracowany model turbiny gazowej z wodnym kotłem odzysknicowym wraz z metodą jego kalibracji w oparciu o dane obiektowe, może posłużyć do zaprognozowania parametrów pracy układu w horyzoncie doby następnej. W tym celu, model obliczeniowy wymaga zasilenia następującymi danymi wejściowymi (które należy uprzednio zaprognozować dla zakładanego horyzontu czasowego):

- temperatura, wilgotność i ciśnienie otoczenia,
- współczynnik poprawkowy dla mocy elektrycznej,
- współczynnik poprawkowy dla jednostkowego zużycia energii chemicznej paliwa,
- współczynnik poprawkowy dla masowego przepływu spalin wylotowych z turbiny,
- współczynnik poprawkowy dla temperatury spalin wylotowych z turbiny,
- spadek ciśnienia powietrza dolotowego do sprężarki,
- spadek ciśnienia spalin wylotowych z turbiny,
- całkowity współczynnik przenikania ciepła kotła odzysknicowego.

Prognoza danych pogodowych pochodzi od zewnętrznego dostawcy prognozy pogody i jest jednocześnie wykorzystywana na potrzeby prognozowania zapotrzebowania na ciepło. Przewidzenie warunków atmosferycznych jest potrzebne do obliczenia parametrów termofizycznych powietrza dolotowego do sprężarki za układem anty-oblodzeniowym. Spadek ciśnienia powietrza dolotowego wynika z aktualnego stanu zanieczyszczenia filtra powietrza. Dla potrzeb symulacji w dobie następnej, przyjęto założenie, że wartość spadku ciśnienia jest taka sama jak w dobie poprzedzającej. Dla współczynników poprawkowych, spadku ciśnienia spalin wylotowych z turbiny oraz całkowitego współczynnika przenikania ciepła kotła, zaproponowano opracowanie modeli predykcyjnych, które w kroku godzinowym będą w stanie zaprognozować wymagane dane wejściowe do symulacji pracy układu turbina-kocioł.

Rozważane modele predykcyjne zostały przedstawiono w równaniach od (6.33) do (6.36). Dla każdej zmiennej, badano zastosowanie czterech modeli, zróżnicowanych względem zastosowanego algorytmu i zakresu danych objaśniających zmienną prognozowaną. Pierwszy model zakłada zastosowanie regresji liniowej temperatury powietrza dolotowego do turbiny. Drugi model bazuje na zastosowaniu liniowej regresji wielorakiej temperatury powietrza dolotowego i ciśnienia atmosferycznego. Kolejne dwa modele opierają się na wykorzystaniu Uogólnionego Modelu Addytywnego GAM. Modele zostały sparametryzowane jak w modelu zapotrzebowaniu na ciepło (w zakresie splajnu kubicznego dla funkcji wygładzających oraz rozkładu Gaussa jako funkcja z eksponentem). Model trzeci wykorzystuje wyłącznie jedną zmienną – temperaturę powietrza dolotowego, a czwarty dodatkowo ciśnienie atmosferyczne. Celem prowadzonych analiz było sprawdzenie, czy model GAM prowadzi do uzyskania poprawy dokładności w prognozowaniu w porównaniu do prostych modeli regresji liniowej.

$$Y_{m01} = \alpha_{m01}T_1 + \beta_{m01} + \varepsilon_{m01} \quad (6.33)$$

$$Y_{m02} = \alpha_{1,m02}T_1 + \alpha_{2,m02}p_0 + \beta_{m02} + \varepsilon_{m02} \quad (6.34)$$

$$Y_{m03} = \alpha_{m03} + s(T_1) + \varepsilon_{m03} \quad (6.35)$$

$$Y_{m04} = \alpha_{m04} + s(T_1) + s(p_0) + \varepsilon_{m04} \quad (6.36)$$

gdzie:

Y – zmienna prognozowana: współczynnik poprawkowy mocy elektrycznej, współczynnik poprawkowy jednostkowego zużycie energii chemicznej paliwa, współczynnik poprawkowy masowego przepływu spalin, współczynnik poprawkowy temperatury spalin, spadek ciśnienia spalin

$\alpha_{m01}, \alpha_{1,m02}, \alpha_{2,m02}, \alpha_{m03}, \alpha_{m04}$ – współczynniki poprawkowe

β_{m01}, β_{m02} – współczynniki regresji

ε – błąd modelu

$s(T_1), s(p_0)$ – funkcje wygładzające temperaturę powietrza dolotowego oraz ciśnienia atmosferyczne

indeks dolny:

$m01, m02, m03, m04$ – modele predykcyjne $m01, m02, m03, m04$

Badane modele do prognozowania całkowitego współczynnika przenikania ciepła kotła odzysknicowego przedstawiają równania od (6.37) do (6.40). W każdym z czterech modeli uwzględniono poza temperaturą powietrza dolotowego T_1 oraz ciśnieniem atmosferycznym p_0 , dodatkowo zmienną w postaci mocy cieplnej palnika dopalającego spaliny $\dot{Q}_{sf}$.

$$kA_{m01} = \alpha_{1,m01}T_1 + \alpha_{m01}\dot{Q}_{sf} + \beta_{m01} + \varepsilon_{m01} \quad (6.37)$$


$$kA_{m02} = \alpha_{1,m02}T_1 + \alpha_{2,m02}p_0 + \alpha_{3,m02}\dot{Q}_{sf} + \beta_{m02} + \varepsilon_{m02} \quad (6.38)$$

$$kA_{m03} = \alpha_{m03} + s(T_1) + s(\dot{Q}_{sf}) + \varepsilon_{m03} \quad (6.39)$$

$$kA_{m04} = \alpha_{m04} + s(T_1) + s(p_0) + s(\dot{Q}_{sf}) + \varepsilon_{m04} \quad (6.40)$$


Dokładność modeli predykcyjnych została oceniona na podstawie ich symulacji pracy na danych z okresu dwóch pełnych lat kalendarzowych 2021-2022. Dla każdego dnia z badanego okresu czasu została wyznaczona prognoza wartości poszczególnych zmiennych prognozowanych w kroku godzinowym. Do uczenia modeli predykcyjnych wykorzystano historyczne dane w rozdzielczości godzinowej, pochodzące z przesuwne go okna czasowego obejmujący okres ostatnich dni z pracy jednostki wytwórczej (podobnie jak dla modelu zapotrzebowania na ciepło). Schemat ideowy uczenia modeli przedstawiono na Rys. 6.17. Każdorazowo, dla dnia w których generowana jest prognoza na dzień następny, modele predykcyjne są uczone w oparciu o dane historyczne z okna przesuwne go (etap kalibracji). Dokonywane są obliczenia mające na celu wyznaczenie rzeczywistych wartości współczynników

poprawkowych, całkowitego współczynnika przenikania ciepła dla kotła. Następnie, w oparciu o nauczone modele, dokonywane są prognozy dla horyzontu doby następnej – zgodnie ze schematem ideowym na Rys. 6.18 (etap prognozowania). Na Rys. 6.19 przedstawiono dla wybranej zmiennej prognozowanej (współczynnik poprawkowy mocy elektrycznej) wynik dopasowania funkcji wygładzających w modelu GAM określonym w równaniu (6.36) dla rozmiaru okna z danymi uczącymi model wynoszącym 15 dni. Z analizy wykresu można odczytać nieliniowy wpływ na zmienną prognozowaną poszczególnych danych wejściowych w modelu.




Rys. 6.17 Schemat uczenia modeli predykcyjnych


ETAP PROGNOZOWANIA



Rys. 6.18 Schemat prognozowania danych produkcyjnych


a)






Rys. 6.19 Funkcje wygładzające zmienną określającą temperaturę powietrza dolotowego (a) oraz ciśnienie atmosferyczne (b) w modelu dla predykcji współczynnika poprawkowego mocy elektrycznej

Na Rys. 6.20 oraz Rys. 6.21 przedstawiono wyniki działania modelu obliczeniowego układu turbina-kocioł przy zastosowaniu modelu do prognozy współczynników poprawkowych zgodnie z modelami *m04* dla wybranej doby z okresu letniego, podczas której jednostka wytwórcza pracowała w godzinach 6:00-17:00. Odchyłki między prognozami mocy elektrycznej i cieplnej, a wartościami faktycznymi były spowodowane w głównej mierze błędami prognozy danych klimatycznych.



Rys. 6.20 Przebieg temperatury powietrza dolotowego do turbiny oraz prognoza mocy elektrycznej wraz z faktycznymi wartościami




Rys. 6.21 Przebieg prognozowanej i faktycznej mocy cieplnej odzyskiwanej w kotle odzysknicowym

6.2.1 Wyniki prognozowania parametrów pracy turbiny i kotła

W celu porównania badanych modeli, obliczono błąd średniokwadratowy RMSE ze wszystkich godzinowych wskazań modeli w analizowanym okresie czasu dwóch lat. Wyniki dokładności prognozy współczynnika poprawkowego mocy elektrycznej zostały przedstawione na Rys. 6.22, gdzie błąd RMSE został obliczony dla analizowanych rozmiarów okien treningowym z danymi uczącymi model od 4 do 70 dni. Analizę przeprowadzono w dwóch scenariuszach (przy użyciu prognozowanych danych pogodowych w dobie następnej i danych rzeczywistych nieobarczonych błędem prognozy pogody). Z analizy wykresu wynika, że model GAM (*m04*) z dwoma zmiennymi objaśniającymi zmienną prognozowaną, osiąga najniższy błąd w horyzoncie doby następnej, zarówno dla prognozowanych, jak i faktycznych danych pogodowych w dobie następnej. Najniższe wartości błędu uzyskano dla rozmiaru okna wynoszącego 15 dni. Dla większych rozmiarów, model wykazuje pogorszoną dokładność w prognozowaniu.

Tab. 6.11 zawiera wartości błędu RMSE zaprognozowanych w dobie następnej parametrów produkcyjnych przy użyciu najbardziej dokładnego modelu *m04* (mocy elektrycznej, mocy cieplnej kotła oraz jednostkowego zużycia energii chemicznej paliwa), dla każdej z dwóch turbin gazowych i dwóch rozmiarów okna uczącego model (15 oraz 30 dni). W zależności od przyjętego rozmiaru okna uzyskuje się zbliżony poziom błędu, a różnice nie przekraczają 1 punktu procentowego dla błędu RMSE. Wykresy na Rys. 6.23 oraz Rys. 6.24 przedstawiają statystykę rozkładu godzinowych błędów względnych dla prognozowanych parametrów z użyciem faktycznych danych pogodowych w dobie nadchodzącej, odpowiednio dla turbiny GT1 oraz turbiny GT2. Zdecydowana większość chwilowych (godzinowych) błędów zawiera się w przedziale

od - 1 do 1 %, dla mocy elektrycznej i cieplnej. Błąd jednostkowego zużycia energii chemicznej paliwa jest na niższym poziomie i zawiera się w większości w przedziale od - 0,4 do 0,4 %.




Rys. 6.22 Błąd RMSE modelu prognozowania współczynnika poprawkowego mocy elektrycznej turbiny GT1

Tab. 6.11 Błąd RMSE modeli predykcyjnych dla turbiny GT1 i GT2 dla okna treningowego 15 oraz 30 dni (przy użyciu faktycznych danych pogodowych na zbiorze testowym w dobie następnej)

Para metr	Turbina GT1			Turbina GT2		
	Faktyczna wartość średnia i odchylenie std.	Błąd RMSE dla okna=15 dni	Błąd RMSE dla okna=30 dni	Faktyczna wartość średnia i odchylenie std.	Błąd RMSE dla okna=15 dni	Błąd RMSE dla okna=30 dni
N_{el}	43,7 +/- 2,82 MW	0,59 MW	0,61 MW	44,2 +/- 3,1 MW	0,67 MW	0,59 MW
$\dot{Q}_{HRHWI}$	57,8 +/- 12,5 MW	1,32 MW	1,38 MW	61,1 +/- 13,3 MW	0,94 MW	1,03 MW
HR	8417,5 +/- 103,1 kJ/kWh	55,09 kJ/kWh	56,17 kJ/kWh	8581,7 +/- 103,0 kJ/kWh	55,02 kJ/kWh	54,21 kJ/kWh



Rys. 6.23 Statystyka godzinowych błędów względnych prognozy mocy elektrycznej, mocy cieplnej i jednostkowego zużycia energii chemicznej paliwa dla turbiny GT1 (dla modelu m04 i okna treningowego 15 dni)




Rys. 6.24 Statystyka godzinowych błędów względnych prognozy mocy elektrycznej, mocy cieplnej i jednostkowego zużycia energii chemicznej paliwa dla turbiny GT2 (dla modelu m04 i okna treningowego 15 dni)

7 Weryfikacja wyników prognozowania zapotrzebowania na ciepło i parametrów produkcyjnych turbin gazowych


Opracowane modele do prognozowania zapotrzebowania na ciepło w sieci ciepłowniczej oraz do prognozowania parametrów produkcyjnych jednostki wytwórczej, zostały zweryfikowane na danych obejmujących pełen rok kalendarzowy 2023. W poprzednich rozdziałach zaprezentowano proces budowania i selekcji modeli do wdrożenia w docelowym narzędziu do planowania pracy elektrociepłowni, który przeprowadzono wykorzystując dane z lat 2021-2022. W ramach analizy w niniejszym rozdziale, dokonano symulacji pracy modeli predykcyjnych na przestrzeni pełnego roku 2023, generując wyniki godzinowych prognoz w horyzoncie doby następnej.

7.1 Weryfikacja modelu zapotrzebowania na ciepło

Do prognoz zapotrzebowania na ciepło zastosowano modele *m02* (model regresji eksponentyjnej temperatury otoczenia) oraz *m09* (model z algorytmem GAM, zapewniający najniższy poziom błędów). Rozmiar przesuwnej okna w czasie z danymi uczącymi model wynosił 15 dni dla miesięcy od grudnia do marca. Dla miesięcy przejściowych, od kwietnia do maja oraz od października do listopada zastosowano rozmiar okna równy 8 dni. Na Rys. 7.1 przedstawiono wyniki prognoz mocy cieplnej oddawanej przez elektrociepłownię do sieci ciepłowniczej w wybranym miesiącu sezonu grzewczego (w lutym). Model *m09* i *m02* poprawnie odwzorowuje zmienne wahania mocy cieplnej w szerokim zakresie mocy cieplnej od ok. 50 do ok. 225 MWt. Na Rys. 7.2 zawarto wyniki prognozowania dla miesiąca z poza okresu grzewczego (w lipcu). Na okres poza sezonem grzewczym, został użyty model *m12* (z oknem z danymi treningowymi równym 14 dni). W tym okresie czasu, moc cieplna zmieniała się od 16 do 23 MW. Widoczne są odchyłki od faktycznie wykonanej mocy cieplnej, które nie przekraczają poziomu ok. 1,5 MW.



Rys. 7.1 Rzeczywiste i prognozowane zapotrzebowanie na ciepło przez sieć ciepłowniczą w lutym



Rys. 7.2 Rzeczywiste i prognozowane zapotrzebowanie na ciepło przez sieć ciepłowniczą w lipcu

Analizę dokładności modeli prognozowania mocy cieplnej przeprowadzono w oparciu o średniomiesięczne wskaźniki błędów MAPE oraz RMSE. Wyniki analizy zostały przedstawione w Tab. 7.1. Przeprowadzono ocenę dokładności modeli predykcyjnych w dwóch scenariuszach, dla prognozowanych oraz rzeczywistych danych pogodowych w horyzoncie doby następnej. Dla prognozowanych danych pogodowych, błąd średniomiesięczny z godzinowych wskazań modelu *m09* zawierał się w przedziale od ok. 4,7 do 8,2 % i był mniejszy o ok. 2 punkty procentowe w porównaniu do modelu *m02*. Podczas kwietnia, maja oraz października błąd wzrósł do wartości przekraczających 10% w ujęciu miesięcznym.

Tab. 7.1 Błąd prognozowania zapotrzebowania na ciepło w miesiącach sezonu grzewczego

Miesiąc	Prognozowane dane pogodowe		Faktyczne dane pogodowe		Prognozowane dane pogodowe		Faktyczne dane pogodowe	
	Błąd MAPE (model m02)	Błąd MAPE (model m09)	Błąd MAPE (model m02)	Błąd MAPE (model m09)	Błąd RMSE (model m02)	Błąd RMSE (model m09)	Błąd RMSE (model m02)	Błąd RMSE (model m09)
styczeń	6,8%	4,7%	5,9%	3,8%	13,89 MW	9,38 MW	12,39 MW	8,09 MW
luty	8,1%	6,3%	7,3%	5,6%	13,85 MW	12,3 MW	12,38 MW	10,23 MW
marzec	11,1%	8,2%	9,2%	7,7%	13,42 MW	10,02 MW	11,47 MW	8,96 MW
kwiecień	15,8%	12,7%	9,8%	7,8%	14,53 MW	11,47 MW	9,76 MW	7,7 MW
maj	14,6%	10,8%	8,3%	7,3%	12,48 MW	9,57 MW	7,19 MW	5,61 MW
październik	14,8%	13,3%	14,1%	13,0%	12,37 MW	10,5 MW	11,72 MW	9,96 MW
listopad	7,8%	6,4%	7,3%	5,8%	9,76 MW	8,05 MW	8,88 MW	7,3 MW
grudzień	7,9%	6,2%	6,4%	4,5%	13,87 MW	10,58 MW	11,6 MW	7,97 MW


Tab. 7.2 zawiera wyniki obliczeń dokładności modelu opracowanego na okres poza sezonem grzewczym. Błąd RMSE zawierał się w przedziale od 0,93 do 1,41 MW i był na zbliżonym poziomie co na danych wykorzystanych do budowy i selekcji docelowego modelu.

Tab. 7.2 Błąd prognozowania zapotrzebowania na ciepło w miesiącach sezonu letniego

Miesiąc	Błąd MAPE (model m12)	Błąd RMSE (model m12)
maj	4,7%	1,17 MW
czerwiec	4,1%	1,00 MW
lipiec	3,3%	0,93 MW
sierpień	3,9%	1,04 MW
wrzesień	5,0%	1,41 MW

7.2 Weryfikacja modelu turbiny gazowej z kotłem odzysknicowym


Na Rys. 7.3 przedstawiono godzinowe przebiegi prognozowanej w dobie następnej mocy elektrycznej dla turbiny gazowej podczas lutego (przy zastosowaniu modelu *m04* z oknem treningowym wynoszącym 15 dni). Na wykresie zaznaczono również rzeczywiste wartości zmiennej prognozowanej. Kolejne wykresy (Rys. 7.4, Rys. 7.5., Rys. 7.6) zawierają odpowiednio wyniki prognozowania mocy cieplnej kotła odzysknicowego, jednostkowego zużycia energii chemicznej paliwa oraz emisji CO₂ podczas pracy jednostki wytwórczej. Podczas prognozowania mocy cieplnej kotła w dobie następnej, założono, że zużycie gazu przez palnik dopalający spaliny w poszczególnych godzinach doby (a tym samym jego moc cieplna) była na takim samym poziomie jak w rzeczywistych, historycznych danych.




Rys. 7.3 Rzeczywista i prognozowana moc elektryczna turbiny gazowej GT1 w lutym

Emisja CO₂ została obliczona w oparciu o wskaźnik emisyjności dla spalanego w badanej elektrociepłowni paliwa wysokometanowego (55,8 kg CO₂ na 1 GJ mocy cieplnej w paliwie). Wskaźnik emisyjności został wyznaczony w oprogramowaniu Epsilon Professional, gdzie przeprowadzono obliczenia rzeczywistego przepływu


masowego CO₂ w spalinach wylotowych z kotła w zadanych warunkach pracy związanych z parametrami termofizycznymi powietrza dolotowego oraz mocy palnika dopalającego spaliny. Skład spalin wyznaczany był na podstawie obliczeń stechiometrycznych procesu spalania. Wyniki obliczeń wskaźnika emisyjności CO₂ przedstawiono na Rys. 7.7. Wykres zawiera wartości dla wskaźnika w zależności od mocy cieplnej w paliwie dostarczanego do komory spalania turbiny i palników dopalających spaliny.




Rys. 7.4 Rzeczywista i prognozowana moc cieplna kotła odzysknicowego HRHWB1 w lutym



Rys. 7.5 Rzeczywiste i prognozowane jednostkowe zużycie energii chemicznej paliwa turbiny GT1 w lutym




Rys. 7.6 Rzeczywisty i prognozowany przebieg emisji CO₂ podczas pracy turbiny GT1 i palnika dopalającego spaliny w lutym




Rys. 7.7 Emisja CO₂ dla kogeneracyjnej turbiny gazowej w zależności od mocy cieplnej w paliwie

Na poniższych Rysunkach przedstawiono wyniki prognozowania mocy elektrycznej (Rys. 7.8) i mocy cieplnej (Rys. 7.9) w wybranym okresie sezonu letniego. Turbina gazowa w tym okresie pracowała w godzinach od 7:00 do 18:00 w zakresie mocy elektrycznej od 34 do 41 MW. Z analizy wykresów wynika, że modele poprawnie odwzorowują zmiany w produkcji energii elektrycznej, wynikających ze zmian parametrów otoczenia na przestrzeni dnia. Niedokładności prognoz, zawierające się w przedziale od ok. -2 do 2%, wynikały w głównej mierze z błędów prognozowania danych pogodowych w dobie następnej. W tym okresie czasu palnik dopalający spaliny nie pracuje, a zróżnicowany poziom mocy cieplnej wynika z bieżących wartości

przepływu masowego oraz temperatury spalin na wlocie do kotła odzysknicowego. Odchylenie pomiędzy mocą cieplną prognozowaną, a rzeczywistą wynosiło do 0,5 MW.




Rys. 7.8 Rzeczywista i prognozowana moc elektryczna turbiny gazowej GT1 w lipcu




Rys. 7.9 Rzeczywista i prognozowana moc cieplna kotła odzysknicowego HRHWB1 w lipcu

Tab. 7.3 oraz Tab. 7.4 zawiera wartości średniomiesięcznych błędów MAPE oraz RMSE modelu do prognozowania mocy elektrycznej, mocy cieplnej, jednostkowego zużycia energii chemicznej paliwa oraz emisji CO₂ dla turbiny GT1. Wyniki dla drugiej turbiny GT2, zostały ujęte w Tab 7.5 oraz Tab. 7.6. Dla prognozowanych danych pogodowych, błąd względny prognozowania mocy elektrycznej wynosi w miesiącach sezonu grzewczego do 2% w ujęciu średniomiesięcznym. W zimie, podczas temperatur niższych niż 4 °C pracuje układ anty-oblodzeniowy turbiny, który stabilizuje temperaturę powietrza dolotowego na stałym poziomie, tym samym błąd prognozowania parametrów powietrza jest niższy. W okresie letnim, moc elektryczna i pozostałe parametry produkcyjne są w większym stopniu uzależnione od zmian parametrów otoczenia, tak więc błąd prognozowania w tym okresie jest zwiększony.

Poza sezonem grzewczym, błąd prognozowania mocy elektrycznej wynosił średniomiesięcznie ok. 3%.



Rys. 7.10 Rzeczywiste i prognozowane jednostkowe zużycie energii chemicznej paliwa turbiny GT1 w lipcu



Rys. 7.11 Rzeczywista i prognozowana emisja CO₂ podczas pracy turbiny GT1 i palnika dopalającego spaliny SF1 w lipcu

Tab. 7.3 Błąd prognozowania parametrów produkcyjnych turbiny GT1 z użyciem faktycznych danych pogodowych w poszczególnych miesiącach

Miesiąc	Faktyczne dane pogodowe							
	Błąd MAPE Mocy Elektrycznej	Błąd MAPE Mocy Ciepłej	Błąd MAPE Jedn. zuż. en. chem. paliwa	Błąd MAPE emisji CO ₂	Błąd RMSE Mocy Elektrycznej	Błąd RMSE Mocy Ciepłej	Błąd RMSE Jedn. zuż. en. chem. paliwa	Błąd RMSE emisji CO ₂
styczeń	0,5%	0,5%	0,2%	0,3%	0,38 MW	0,5 MW	17,73 kJ/kWh	0,15 t/h
luty	1,0%	0,8%	0,2%	0,8%	0,66 MW	0,62 MW	24,87 kJ/kWh	0,29 t/h

Miesiąc	Faktyczne dane pogodowe							
	Błąd MAPE Mocy Elektrycznej	Błąd MAPE Mocy Ciepłej	Błąd MAPE Jedn. zuż. en. chem. paliwa	Błąd MAPE emisji CO ₂	Błąd RMSE Mocy Elektrycznej	Błąd RMSE Mocy Ciepłej	Błąd RMSE Jedn. zuż. en. chem. paliwa	Błąd RMSE emisji CO ₂
marzec	1,1%	1,0%	0,3%	0,8%	0,74 MW	0,69 MW	38,64 kJ/kWh	0,28 t/h
kwiecień	0,8%	1,3%	0,2%	0,6%	0,46 MW	0,86 MW	18,83 kJ/kWh	0,19 t/h
maj	1,0%	1,6%	0,6%	0,9%	0,51 MW	0,88 MW	60,13 kJ/kWh	0,2 t/h
czerwiec	1,8%	1,0%	0,8%	1,1%	0,87 MW	0,54 MW	74,79 kJ/kWh	0,27 t/h
lipiec	0,8%	0,6%	0,4%	1,2%	0,41 MW	0,37 MW	44,55 kJ/kWh	0,23 t/h
sierpień	2,0%	1,4%	0,3%	1,7%	0,8 MW	0,73 MW	26,38 kJ/kWh	0,33 t/h
wrzesień	0,6%	1,2%	0,5%	0,6%	0,37 MW	0,79 MW	46,47 kJ/kWh	0,15 t/h
październik	0,5%	1,3%	0,5%	0,6%	0,32 MW	0,69 MW	42,5 kJ/kWh	0,17 t/h
listopad	0,8%	0,8%	0,4%	0,6%	0,42 MW	0,64 MW	43,81 kJ/kWh	0,18 t/h
grudzień	0,9%	0,7%	0,6%	0,7%	0,64 MW	0,65 MW	67,53 kJ/kWh	0,25 t/h

Tab. 7.4 Błąd prognozowania parametrów produkcyjnych turbiny GT1 z użyciem prognozowanych danych pogodowych w poszczególnych miesiącach

Miesiąc	Prognozowane dane pogodowe							
	Błąd MAPE Mocy Elektrycznej	Błąd MAPE Mocy Ciepłej	Błąd MAPE Jedn. zuż. en. chem. paliwa	Błąd MAPE emisji CO ₂	Błąd RMSE Mocy Elektrycznej	Błąd RMSE Mocy Ciepłej	Błąd RMSE Jedn. zuż. en. chem. paliwa	Błąd RMSE emisji CO ₂
styczeń	1,0%	0,7%	0,1%	0,8%	0,53 MW	0,61 MW	16,08 kJ/kWh	0,25 t/h
luty	1,4%	0,8%	0,2%	1,1%	0,75 MW	0,63 MW	26,65 kJ/kWh	0,34 t/h
marzec	1,3%	1,0%	0,3%	1,2%	0,77 MW	0,67 MW	34,32 kJ/kWh	0,33 t/h
kwiecień	1,7%	1,7%	0,2%	1,5%	0,97 MW	1,13 MW	24,83 kJ/kWh	0,41 t/h
maj	1,8%	1,6%	0,5%	1,9%	0,95 MW	0,94 MW	55,05 kJ/kWh	0,45 t/h
czerwiec	2,2%	1,5%	0,7%	1,7%	1,02 MW	0,85 MW	68,22 kJ/kWh	0,4 t/h
lipiec	2,2%	1,5%	0,5%	2,0%	1,03 MW	0,78 MW	48,33 kJ/kWh	0,45 t/h
sierpień	1,6%	2,0%	0,3%	1,3%	0,81 MW	1,08 MW	35,58 kJ/kWh	0,31 t/h
wrzesień	1,5%	1,1%	0,7%	1,1%	0,74 MW	0,72 MW	61,64 kJ/kWh	0,24 t/h
październik	1,6%	1,1%	0,6%	1,4%	0,82 MW	0,64 MW	53,42 kJ/kWh	0,31 t/h
listopad	0,5%	1,0%	0,4%	0,6%	0,33 MW	0,76 MW	42,43 kJ/kWh	0,19 t/h
grudzień	1,2%	0,7%	0,6%	0,9%	0,7 MW	0,64 MW	68,34 kJ/kWh	0,28 t/h

Tab. 7.5 Błąd prognozowania parametrów produkcyjnych turbiny GT2 z użyciem faktycznych danych pogodowych w poszczególnych miesiącach


Miesiąc	Faktyczne dane pogodowe							
	Błąd MAPE Mocy Elektrycznej	Błąd MAPE Mocy Ciepłej	Błąd MAPE Jedn. zuż. en. chem. paliwa	Błąd MAPE emisji CO ₂	Błąd RMSE Mocy Elektrycznej	Błąd RMSE Mocy Ciepłej	Błąd RMSE Jedn. zuż. en. chem. paliwa	Błąd RMSE emisji CO ₂
styczeń	0,5%	0,5%	0,2%	0,3%	0,46 MW	1,04 MW	23,38 kJ/kWh	0,18 t/h
luty	0,9%	0,9%	0,3%	0,7%	0,6 MW	1,00 MW	28,98 kJ/kWh	0,25 t/h
marzec	0,8%	0,8%	0,4%	0,7%	0,58 MW	0,94 MW	46,03 kJ/kWh	0,25 t/h
kwiecień	0,9%	0,9%	0,2%	0,8%	0,53 MW	0,7 MW	19,91 kJ/kWh	0,23 t/h
maj	0,8%	0,8%	0,5%	0,8%	0,44 MW	0,36 MW	51,01 kJ/kWh	0,2 t/h
czerwiec	0,9%	0,9%	0,5%	0,9%	0,43 MW	0,26 MW	52,61 kJ/kWh	0,2 t/h
lipiec	0,9%	0,9%	0,3%	0,7%	0,44 MW	0,28 MW	36,66 kJ/kWh	0,17 t/h
sierpień	1,1%	1,1%	0,3%	0,8%	0,56 MW	0,32 MW	39,28 kJ/kWh	0,21 t/h
wrzesień	0,7%	0,7%	0,2%	0,6%	0,37 MW	0,72 MW	24,82 kJ/kWh	0,15 t/h
październik	0,4%	0,5%	0,3%	0,5%	0,31 MW	1,16 MW	35,43 kJ/kWh	0,16 t/h
listopad	0,4%	0,4%	0,4%	0,4%	0,23 MW	1,46 MW	39,47 kJ/kWh	0,14 t/h
grudzień	0,7%	0,7%	0,6%	0,6%	0,56 MW	1,04 MW	69,76 kJ/kWh	0,29 t/h

Tab. 7.6 Błąd prognozowania parametrów produkcyjnych turbiny GT2 z użyciem prognozowanych danych pogodowych w poszczególnych miesiącach


Miesiąc	Prognozowane dane pogodowe							
	Błąd MAPE Mocy Elektrycznej	Błąd MAPE Mocy Ciepłej	Błąd MAPE Jedn. zuż. en. chem. paliwa	Błąd MAPE emisji CO ₂	Błąd RMSE Mocy Elektrycznej	Błąd RMSE Mocy Ciepłej	Błąd RMSE Jedn. zuż. en. chem. paliwa	Błąd RMSE emisji CO ₂
styczeń	0,9%	1,2%	0,2%	0,8%	0,53 MW	1,07 MW	22,03 kJ/kWh	0,23 t/h
luty	1,3%	1,0%	0,3%	1,0%	0,8 MW	0,83 MW	33,16 kJ/kWh	0,33 t/h
marzec	1,4%	1,2%	0,4%	1,3%	0,8 MW	0,95 MW	44,12 kJ/kWh	0,37 t/h
kwiecień	1,5%	1,1%	0,2%	1,3%	0,91 MW	0,72 MW	26,71 kJ/kWh	0,38 t/h
maj	1,9%	1,2%	0,5%	1,9%	0,96 MW	0,71 MW	50,63 kJ/kWh	0,45 t/h
czerwiec	3,3%	1,8%	0,8%	2,8%	1,54 MW	1,01 MW	86,88 kJ/kWh	0,61 t/h
lipiec	3,8%	1,9%	0,8%	3,0%	1,7 MW	1,05 MW	88,13 kJ/kWh	0,66 t/h
sierpień	2,7%	1,5%	0,6%	2,1%	1,23 MW	0,85 MW	63,00 kJ/kWh	0,47 t/h
wrzesień	1,9%	1,3%	0,4%	1,5%	0,98 MW	0,91 MW	44,28 kJ/kWh	0,38 t/h
październik	1,3%	1,2%	0,3%	1,1%	0,9 MW	1,44 MW	37,04 kJ/kWh	0,43 t/h
listopad	0,9%	1,8%	0,4%	0,8%	0,48 MW	1,44 MW	39,06 kJ/kWh	0,25 t/h
grudzień	1,1%	1,0%	0,7%	1,0%	0,74 MW	0,94 MW	74,43 kJ/kWh	0,34 t/h

Modele predykcyjne współczynników poprawkowych w modelu turbiny gazowej z wodnym kotłem odzysknicowym, oparte o algorytm GAM, umożliwiły istotną poprawę dokładności prognozowania parametrów produkcyjnych. Model *m04* (z funkcją wygładzającą temperaturę powietrza dolotowego oraz ciśnienia atmosferycznego), w porównaniu do modelu *m01* (z regresją liniową jednej zmiennej


– temperatury powietrza dolotowego), pozwolił na osiągnięcie lepszej dokładności w prognozowaniu istotnych dla planowania pracy wskaźników, jak godzinowa produkcja energii elektrycznej, mocy cieplnej i zużycie paliwa gazowego. Na Rys. 7.12 przedstawiono porównanie średniomiesięcznego błędu MAPE dla mocy elektrycznej, na Rys. 7.13 dla jednostkowego zużycia energii chemicznej paliwa, a na Rys. 7.14 dla mocy cieplnej.



Rys. 7.12 Porównanie średniomiesięcznego błędu MAPE prognozowania mocy elektrycznej dla modeli m01 oraz m04 (przy użyciu prognozowanych danych w dobie następnej)



Rys. 7.13 Porównanie średniomiesięcznego błędu MAPE prognozowania jednostkowego zużycia energii chemicznej paliwa dla modeli m01 oraz m04 (przy użyciu prognozowanych danych w dobie następnej)



Rys. 7.14 Porównanie średniomiesięcznego błędu MAPE prognozowania mocy cieplnej kotła odzysknicowego dla modeli m01 oraz m04 (przy użyciu prognozowanych danych w dobie następnej)

8 Optymalizacja produkcji ciepła w dobie następnej

W niniejszym rozdziale omówiono zagadnienie planowania pracy jednostek wytwórczych badanej elektrociepłowni w horyzoncie doby następnej wykorzystując jako dane wejściowe wyniki z modeli prognostycznych zapotrzebowania na ciepło i parametrów produkcyjnych turbin gazowych. Proces planowania, ma na celu zaplanowanie najbardziej korzystnego scenariusza pokrycia spodziewanego profilu zapotrzebowania na ciepło przez jednostki wytwórcze. Przyjęte zadanie optymalizacji jest związane z maksymalizacją funkcji celu, zdefiniowanej równaniem (8.1). Funkcja celu określa umowny zysk operacyjny dla elektrociepłowni (nie zawierający kosztów stałych), rozumiany jako różnica pomiędzy przychodami, a kosztami wytwarzania ciepła i energii elektrycznej.

$$\begin{aligned} \max \rightarrow Z = \sum_{t=1}^{24} & (c_{el,t}(P_t^{GT1} + P_t^{GT2}) + c_h \dot{Q}_t - c_e(E_t^{GT1} + E_t^{GT2} + E_t^{SF1} + E_t^{SF2} + E_t^{HOB1-4}) \\ & - c_f(F_t^{GT1} + F_t^{GT2} + F_t^{SF1} + F_t^{SF2} + F_t^{HOB1-4}) - (c_s^{GT1} + c_s^{GT2})) \end{aligned} \quad (8.1)$$

gdzie:

Z – zysk operacyjny w analizowanej dobie, PLN

$c_{el,t}$ – cena energii elektrycznej w godzinie t , PLN/MWh

c_h – cena ciepła, PLN/MWh

c_e – cena emisji CO₂, PLN/t

c_f – cena paliwa gazowego, PLN/MWh

c_s – koszt rozruchu turbiny gazowej, PLN

P_t^u – produkcja energii elektrycznej przez jednostkę wytwórczą u w godzinie t , MWh

$\dot{Q}_t$ – ciepło oddawane do miejskiej sieci ciepłowniczej (po odjęciu potrzeb własnych), MWh

E_t^u – emisja CO₂ przez jednostkę wytwórczą u w godzinie t , MWh

F_t^u – zużycie paliwa gazowego (energia chemiczna zawarta w paliwie) przez jednostkę wytwórczą u w godzinie t , MWh

Indeks górny: GT1 – turbina gazowa 1, GT2 – turbina gazowa 2, HRHWB1 – kocioł odzysknicowy 1, HRHWB2 – kocioł odzysknicowy 2, SF1 – palnik dopalający 1, SF2 – palnik dopalający 2

Dane dotyczące mocy elektrycznej turbin gazowych, mocy cieplnej kotłów odzysknicowych i zużycia gazu obliczane są z modelu termodynamicznego opisanego w Rozdziale 6.1. Energia chemiczna zawarta w paliwie pobieranym przez palniki uzupełniające SF jest obliczana z przyjętej sprawności na poziomie 97,1%, zgodnie ze wzorem (8.2). Przy obliczeniach paliwa pobieranego przez gazowe kotły rezerwowo-szczytowe, założono sprawność równą 95,9% - wzór (8.3). Emisja CO₂ związana z pracą poszczególnych jednostek wytwórczych, jest obliczana przy użyciu wskaźnika emisyjności dla spalane paliwa wysokometanowego (55,8 kg CO₂ na 1 GJ mocy cieplnej w paliwie).

$$F_t^{SF} = \frac{\dot{Q}_t^{SF}}{0,971} \quad (8.2)$$

$$F_t^{HOB} = \frac{\dot{Q}_t^{HOB}}{0,959} \quad (8.3)$$

Podstawowymi kryteriami zadania optymalizacyjnego są następujące uwarunkowania:

- Prognozowane zapotrzebowanie na moc cieplną potrzebną do oddania do sieci ciepłowniczej w każdej godzinie doby musi być bezwzględnie pokryte.
- Turbiny gazowe pracują zawsze z maksymalnym obciążeniem, co zapewnia maksymalną sprawność wytwarzania energii elektrycznej.
- Akumulator ciepła jest ładowany, gdy produkcja ciepła w kotle odzysknicowym przekracza bieżące zapotrzebowanie przez sieć ciepłowniczą. Maksymalna moc ładowania i rozładowania akumulatora wynosi 52 MW, a pojemność cieplna 600 MWh. Minimalny stan naładowania akumulatora wynosi 50 MWh. Akumulator ma możliwość pracy, gdy wymagane ciśnienie wody zasilającej sieć ciepłowniczą jest mniejsze niż 0,95 MPa (jest przeznaczony do pracy na okres sezonu przejściowego i letniego kiedy pracuje jedna z turbin gazowych). Stan naładowania akumulatora w początkowej godzinie doby jest wymaganą daną wejściową w obliczeniach wartości funkcji celu.

Funkcję celu maksymalizowano poprzez zmianę następujących całkowitych zmiennych decyzyjnych:

- $GT1_{start}$ – początkowa godzina pracy turbiny gazowej GT1,
- $GT1_{stop}$ – końcowa godzina pracy turbiny gazowej GT1,
- $GT2_{start}$ – początkowa godzina pracy turbiny gazowej GT2,
- $GT2_{stop}$ – końcowa godzina pracy turbiny gazowej GT2.

Zmienne decyzyjne podlegają następującym ograniczeniom:

- $0 \leq GT1_{start} \leq 23$
- $0 \leq GT1_{stop} \leq 23$
- $0 \leq GT2_{start} \leq 23$
- $0 \leq GT2_{stop} \leq 23$
- $GT1_{start} \geq GT1_{stop}$
- $GT2_{start} \geq GT2_{stop}$

Tak więc, maksymalna wartość funkcji celu jest poszukiwana poprzez sprawdzanie godziny załączenia i czasu pracy turbin gazowych, pracujących zawsze z pełnym obciążeniem.

Zadanie optymalizacyjne rozwiązywane jest przy użyciu dodatku Solver do programu Microsoft Excel. Zastosowano algorytm ewolucyjny. Profil pracy jednostek wytwórczych i akumulatora ciepła jest w każdej godzinie rozpatrywanej doby wyznaczany biorąc pod uwagę poniższe założenia:

- Na podstawie modelu prognozowania zapotrzebowania na ciepło obliczany jest spodziewany godzinowy profil wymaganej mocy cieplnej na wprowadzeniu z elektrociepłowni do sieci ciepłowniczej.


- Na podstawie modelu do obliczeń parametrów produkcyjnych turbin gazowych, wyznaczane są możliwości wytwórcze turbin w zakresie produkcji energii elektrycznej, ciepła odzyskiwanego w kotle oraz zapotrzebowanie na paliwo gazowe w poszczególnych godzinach doby.
- Dla każdej godziny doby w horyzoncie czasowym planowania, moc cieplna poszczególnych jednostek jest wyznaczana w następujący sposób:
 - Jeżeli sumaryczna moc cieplna produkowana przez kotły HRHWP1 i HRHWP2 (po odjęciu potrzeb własnych obiektu wynikających z zapotrzebowania na ciepło do układu podgrzewu gazu i układu anty-oblodzeniowego) jest większa niż wymagana przez sieć ciepłowniczą, to akumulator ciepła jest ładowany nadwyżką ciepła (różnicą między produkcją, a poborem przez sieć), pod warunkiem że aktualny stan naładowania akumulatora to umożliwia.
 - Jeżeli sumaryczna moc cieplna produkowana przez kotły HRHWP1 i HRHWP2 jest mniejsza niż wymagana przez sieć ciepłowniczą, to akumulator ciepła jest rozładowywany. Jeżeli akumulator jest niedyspozycyjny lub po rozładowaniu akumulatora występuje deficyt ciepła, to uruchamiane są palniki dopalające spaliny SF, w celu uzupełnienia brakującego poziomu ciepła (z możliwościami zwiększenia mocy cieplnej pojedynczego kotła w zakresie od 6 do 70 MWt). Jeżeli pracują dwie turbiny w danej godzinie, to moc palników jest równomiernie rozłożona.
 - Jeżeli sumaryczna moc cieplna produkowana przez kotły z palnikami uzupełniającymi jest nadal mniejsza niż zapotrzebowanie sieci, to uruchamiane są kotły rezerwowo-szczytowe HOB z wymaganym poziomem mocy cieplnej.

8.1 Wyniki optymalizacji produkcji w dobie następnej

Na Rys. 8.1 przedstawiono wyniki działania optymalizatora dla wybranej doby ze stycznia. W analizowanym przypadku, zaprognozowane zapotrzebowanie na ciepło wynosiło od ok. 131 do ok. 142 MWt. Dla tej doby, największą wartość zysku operacyjnego uzyskano dla turbin pracujących pełną dobę. W tym scenariuszu, podczas całej doby następuje generacja energii elektrycznej, co wpływa na osiągnięcie maksymalnych korzyści operacyjnych. W każdej godzinie doby pracowały palniki dopalające spaliny wlotowe do kotłów, w celu zwiększenia produkowanej mocy cieplnej do wymaganego zapotrzebowania sieci ciepłowniczej.

W Tab. 8.1 oraz Tab. 8.2 zawarto odpowiednio zaprognozowane parametry produkcyjne przewidzianych do pracy jednostek wytwórczych oraz błędy względne prognoz w poszczególnych godzinach doby. Błąd prognozy mocy elektrycznej turbin nie przekracza 1%. Błąd w prognozie zużycia paliwa gazowego i poziomu emisji był zwiększony, kiedy model zapotrzebowania na ciepło wykazywał relatywnie niską dokładność. Jest to spowodowane niedokładnym przewidywaniem profilu pracy palnika dopalającego spaliny, którego zadaniem było dostosowanie do rzeczywistego, wymaganego zapotrzebowania przez sieć ciepłowniczą, w związku

z zapotrzebowaniem przekraczającym poziom odzysku ciepła przez kocioł odzysknicowy.



Rys. 8.1 Profil produkcji ciepła przez jednostki wytwórcze w wybranej dobie stycznia

Tab. 8.1 Prognoza parametrów produkcyjnych w wybranej dobie stycznia


Godzina	Moc cieplna do MSC, MW	Moc cieplna HRHWP1, MW	Moc elektryczna GT1, MW	Moc cieplna w paliwie GT1+SF1, MW	Moc cieplna HRHWP2, MW	Moc elektryczna GT2, MW	Moc cieplna w paliwie GT2+SF2, MW	Emisja , t
0	144,33	73,4	44,9	130,1	75,8	44,9	134,5	52,9
1	142,25	72,3	44,9	128,7	74,7	44,9	133,1	52,4
2	140,69	71,6	44,9	128,1	74,0	44,9	132,5	52,1
3	137,58	70,0	44,7	127,5	72,4	44,7	131,6	51,4
4	134,66	68,6	44,7	126,5	71,0	44,7	130,9	50,8
5	132,41	67,5	44,6	125,2	69,8	44,6	129,4	50,3
6	131,72	67,1	44,6	124,4	69,4	44,6	128,8	50,1
7	131,86	67,2	44,6	123,6	69,4	44,6	127,9	50,1
8	132,41	67,5	44,5	123,5	69,7	44,5	127,9	50,2
9	133,84	68,2	44,5	124,0	70,4	44,5	128,2	50,4
10	134,33	68,4	44,4	124,7	70,6	44,4	128,9	50,4
11	136,07	69,3	44,5	125,7	71,6	44,5	130,0	50,8
12	137,32	69,9	44,5	128,4	72,2	44,5	132,7	51,1
13	138,41	70,4	44,4	130,2	72,7	44,4	134,4	51,3
14	139,26	70,9	44,4	131,8	73,2	44,4	136,1	51,5
15	140,66	71,6	44,5	133,0	73,9	44,5	137,4	51,8
16	141,63	72,1	44,5	131,6	74,4	44,5	135,8	52,0
17	142,58	72,6	44,5	130,2	74,9	44,5	134,4	52,2
18	142,45	72,5	44,5	129,4	74,8	44,5	133,7	52,2
19	142,82	72,7	44,5	129,0	74,9	44,5	133,3	52,2
20	143,01	72,8	44,5	128,9	75,0	44,5	133,1	52,3
21	142,76	72,7	44,6	129,0	74,9	44,6	133,1	52,3
22	141,27	72,0	44,7	128,5	74,2	44,7	132,7	52,1
23	139,77	71,2	44,7	128,0	73,4	44,7	132,1	51,8

Tab. 8.2 Błędy względne prognozowania parametrów produkcyjnych w wybranej dobie stycznia


Godzina	Moc cieplna do MSC, %	Moc cieplna HRHWP1, %	Moc elektryczna GT1, %	Moc cieplna w paliwie GT1+SF1, %	Moc cieplna HRHWP2, %	Moc elektryczna GT2, %	Moc cieplna w paliwie GT2+SF2, %	Emisja, %
0	5,9	2,0	0,60	1,0	2,6	0,53	1,5	1,0
1	6,4	2,4	0,50	1,2	2,9	0,73	1,7	1,1
2	6,0	2,3	0,64	1,1	2,7	0,66	1,6	1,2
3	4,2	0,6	0,73	0,2	1,0	0,50	0,7	0,2
4	3,2	0,1	0,69	0,3	0,3	0,58	0,1	0,3
5	3,2	0,2	0,67	0,4	0,4	0,63	0,2	0,1
6	3,6	0,1	0,56	0,1	0,8	0,49	0,3	0,0
7	4,8	1,3	0,43	0,5	1,8	0,36	0,9	0,5
8	5,3	1,8	0,62	0,7	2,4	0,57	1,0	0,7
9	5,8	2,1	0,56	0,8	2,6	0,45	1,2	0,8
10	4,9	1,3	0,56	0,2	1,7	0,47	0,7	0,4
11	4,7	1,0	0,35	0,3	1,6	0,52	0,7	0,4
12	1,9	1,7	0,44	1,3	1,1	0,60	0,7	1,1
13	0,2	3,4	0,59	2,3	2,7	0,52	1,6	2,2
14	1,4	4,7	0,49	3,1	4,1	0,45	2,5	3,0
15	1,8	5,1	0,45	3,4	4,5	0,62	2,7	3,2
16	1,0	2,8	0,50	2,0	2,1	0,44	1,3	1,9
17	3,6	0,4	0,56	0,5	0,4	0,41	0,1	0,5
18	4,5	0,3	0,46	0,0	1,2	0,35	0,5	0,1
19	5,3	1,1	0,43	0,4	1,9	0,29	0,8	0,3
20	5,6	1,4	0,44	0,6	2,1	0,18	1,0	0,7
21	5,7	1,4	0,41	0,5	2,2	0,16	1,0	0,6
22	5,4	1,3	0,28	0,5	2,0	0,26	0,9	0,6
23	5,0	1,1	0,37	0,2	1,7	0,14	0,8	0,5

Wyniki optymalizacji produkcji dla doby z października (okresu przejściowego pomiędzy latem, a zimą) prezentuje Rys. 8.2. W godzinach nocnych, pracuje turbina GT1, a moc cieplna jest produkowana na kotle odzysknicowym HRHWP-1 przy pracującym palniku SF-1. W momencie wysokich cen energii elektrycznej, między 15:00 a 18:00, załączana jest druga turbina, a nadmiar ciepła z pracującego kotła HRHWP-2 kierowany jest do akumulatora ciepła, który jest rozładowywany w następnych godzinach (ujemna moc cieplna na wykresie dla ACU oznacza moc jego ładowania). Rys. 8.3 przedstawia wykres konturowy z wartościami funkcji celu, w zależności od godziny uruchomienia i czasu pracy turbiny GT2. Wartości funkcji celu na wykresie zostały znormalizowane względem wartości maksymalnej.

W Tab. 8.3 oraz Tab. 8.4 zawarto odpowiednio zaprognozowane parametry produkcyjne przewidzianych do pracy jednostek wytwórczych oraz błędy względne prognoz w poszczególnych godzinach doby. Turbina pod wpływem zmian temperatur podczas dnia wykazuje zróżnicowany poziom produkcji energii elektrycznej. Średniodobowy błąd prognozy produkcji energii elektrycznej wyniósł ok. 0,4%.



Rys. 8.2 Profil produkcji ciepła przez jednostki wytwórcze w wybranej dobie października



Rys. 8.3 Wartość zmiennej optymalizowanej w zależności od czasu pracy i godziny załączenia turbiny GT2

Tab. 8.3 Prognoza parametrów produkcyjnych w wybranej dobie października

Godzina	Moc cieplna do MSC, MW	Moc cieplna HRHWB1, MW	Moc elektryczna GT1, MW	Moc cieplna w paliwie GT1+SF1, MW	Moc cieplna HRHWB2, MW	Moc elektryczna GT2, MW	Moc cieplna w paliwie GT2+SF2, MW	Emisja, t
0	76,96	77,8	44,1	136,7	-	-	-	27,2
1	78,82	79,6	44,4	139,5	-	-	-	27,8
2	78,16	79,1	44,6	139,5	-	-	-	27,8
3	75,94	76,8	44,7	137,4	-	-	-	27,4
4	76,55	77,4	44,9	138,4	-	-	-	27,6
5	77,89	78,8	45,2	140,6	-	-	-	28,0
6	77,68	78,6	45,2	140,6	-	-	-	28,0

Godzina	Moc cieplna do MSC, MW	Moc cieplna HRHWPB1, MW	Moc elektryczna GT1, MW	Moc cieplna w paliwie GT1+SF1, MW	Moc cieplna HRHWPB2, MW	Moc elektryczna GT2, MW	Moc cieplna w paliwie GT2+SF2, MW	Emisja, t
7	73,30	74,2	44,8	135,2	-	-	-	27,0
8	66,48	67,4	44,0	126,0	-	-	-	25,1
9	60,74	61,5	43,1	117,2	-	-	-	23,4
10	58,56	59,4	42,7	114,0	-	-	-	22,7
11	55,02	55,8	41,9	108,8	-	-	-	21,7
12	51,05	51,9	40,9	102,8	-	-	-	20,5
13	48,29	49,0	40,2	98,3	-	-	-	19,6
14	49,09	49,8	40,2	99,2	-	-	-	19,8
15	52,69	47,7	40,8	98,3	47,9	41,4	97,6	39,0
16	58,28	48,1	41,6	99,9	48,0	41,6	97,5	39,4
17	62,47	48,1	41,9	100,5	48,1	41,9	97,9	39,6
18	65,22	48,1	42,2	101,1	48,1	41,8	97,7	39,7
19	66,95	48,1	42,1	101,0	-	-	-	20,1
20	67,84	48,0	42,1	100,9	-	-	-	20,1
21	69,34	48,1	42,5	101,7	-	-	-	20,3
22	70,19	48,0	42,9	102,5	-	-	-	20,4
23	70,32	47,6	43,1	103,0	-	-	-	20,5


Tab. 8.4 Błędy prognozowania parametrów produkcyjnych w wybranej dobie października

Godzina	Moc cieplna do MSC, %	Moc cieplna HRHWPB1, %	Moc elektryczna GT1, %	Moc cieplna w paliwie GT1+SF1, %	Moc cieplna HRHWPB2, %	Moc elektryczna GT2, %	Moc cieplna w paliwie GT2+SF2, %	Emisja, %
0	1,5	8,3	0,31	5,3	-	-	-	5,5
1	0,1	6,9	0,09	4,3	-	-	-	4,3
2	1,3	8,0	0,07	4,6	-	-	-	4,7
3	4,7	11,6	0,10	6,5	-	-	-	6,5
4	2,3	9,7	0,12	5,3	-	-	-	5,3
5	3,3	10,4	0,09	5,7	-	-	-	5,8
6	4,8	11,9	0,35	6,6	-	-	-	6,8
7	10,8	17,6	0,94	10,7	-	-	-	10,6
8	15,3	22,0	1,18	13,8	-	-	-	13,9
9	11,7	19,1	1,06	12,5	-	-	-	12,4
10	2,8	13,1	0,45	7,4	-	-	-	7,5
11	3,2	13,9	0,21	8,0	-	-	-	7,9
12	7,1	16,9	0,11	10,0	-	-	-	10,0
13	7,2	17,6	0,38	10,8	-	-	-	10,8
14	7,2	17,3	0,50	10,7	-	-	-	10,6
15	5,2	20,8	0,29	12,0	2,3	0,17	0,2	6,5
16	2,6	0,1	0,06	0,3	0,7	0,12	0,4	0,0
17	4,4	0,3	0,33	0,4	1,0	0,06	0,4	0,3
18	1,6	0,6	0,35	0,7	0,9	0,16	0,5	0,5
19	0,9	0,5	0,18	0,7	-	-	-	0,5
20	1,0	1,6	0,22	0,5	-	-	-	0,4


Godzina	Moc cieplna do MSC, %	Moc cieplna HRHWPB1, %	Moc elektryczna GT1, %	Moc cieplna w paliwie GT1+SF1, %	Moc cieplna HRHWPB2, %	Moc elektryczna GT2, %	Moc cieplna w paliwie GT2+SF2, %	Emisja, %
21	0,6	1,8	0,43	0,9	-	-	-	0,9
22	1,1	2,4	0,77	1,0	-	-	-	0,8
23	1,8	3,2	0,51	0,9	-	-	-	10,6

Profil pracy elektrociepłowni w dobie z okresu letniego (podczas sierpnia) przedstawiono poniżej na Rys. 8.4. W tym scenariuszu, jedna z turbin gazowych pracuje z maksymalnym obciążeniem podczas szczytowych cen energii elektrycznej, a nadmiar ciepła produkowanego w kotle trafia do akumulatora. W pozostałych godzinach doby, zapotrzebowanie na ciepło przez sieć ciepłowniczą jest pokrywane z rozładowania akumulatora ciepła, podczas postoju turbiny. Rys. 8.5 przedstawia wykres konturowy z wartościami funkcji celu, w zależności od godziny uruchomienia i czasu pracy turbiny GT1. Najwyższą wartość zysku operacyjnego otrzymano dla pracy turbiny w godzinach 7:00 – 19:00.

W Tab. 8.5 oraz Tab. 8.6 zawarto odpowiednio zaprognozowane parametry produkcyjne przewidzianych do pracy jednostek wytwórczych oraz błędy względne prognoz w poszczególnych godzinach doby. Błąd dla mocy elektrycznej zawierał się w przedziale od 0,5 do 1,8%, a błąd mocy cieplnej nie przekroczył 1%. Średniodobowy błąd względny modelu zapotrzebowania na ciepło kształtował się na poziomie 2,2%, a błąd prognozowania zużycia paliwa gazowego 1,03%.



Rys. 8.4 Profil produkcji ciepła przez jednostki wytwórcze w wybranej dobie sierpnia



Rys. 8.5 Wartość zmiennej optymalizowanej w zależności od czasu pracy i godziny załączenia turbiny GT1

Tab. 8.5 Prognoza parametrów produkcyjnych w wybranej dobie sierpnia

Godzina	Moc cieplna do MSC, MW	Moc cieplna HRHWB1, MW	Moc elektryczna GT1, MW	Moc cieplna w paliwie GT1+SF1, MW	Moc cieplna HRHWB2, MW	Moc elektryczna na GT2, MW	Moc cieplna w paliwie GT2+SF2, MW	Emisja, t
0	21,89	-	-	-	-	-	-	-
1	21,91	-	-	-	-	-	-	-
2	21,72	-	-	-	-	-	-	-
3	21,27	-	-	-	-	-	-	-
4	20,81	-	-	-	-	-	-	-
5	20,46	-	-	-	-	-	-	-
6	20,10	-	-	-	-	-	-	-
7	20,10	48,0	39,3	95,5	-	-	-	19,0
8	19,08	47,2	37,9	93,0	-	-	-	18,5
9	19,30	46,4	36,5	90,4	-	-	-	18,0
10	19,46	46,1	36,0	89,5	-	-	-	17,8
11	19,86	46,1	36,1	89,6	-	-	-	17,9
12	19,96	46,1	36,1	89,7	-	-	-	17,9
13	20,11	46,1	36,3	90,0	-	-	-	17,9
14	20,09	46,3	36,4	90,1	-	-	-	18,0
15	20,16	46,1	36,1	89,6	-	-	-	17,9
16	20,84	46,4	36,7	90,7	-	-	-	18,1
17	21,03	47,5	38,3	93,7	-	-	-	18,7
18	20,86	47,6	38,7	94,5	-	-	-	18,8
19	21,25	48,1	39,4	95,7	-	-	-	19,1
20	23,28	-	-	-	-	-	-	-
21	23,60	-	-	-	-	-	-	-
22	23,40	-	-	-	-	-	-	-
23	24,13	-	-	-	-	-	-	-


Tab. 8.6 Błędy prognozowania parametrów produkcyjnych w wybranej dobie sierpnia

Godzina	Moc cieplna do MSC, %	Moc cieplna HRHWP1, %	Moc elektryczna GT1, %	Moc cieplna w paliwie GT1+SF1, %	Moc cieplna HRHWP2, %	Moc elektryczna GT2, %	Moc cieplna w paliwie GT2+SF2, %	Emisja, %
0	2,8	-	-	-	-	-	-	-
1	1,3	-	-	-	-	-	-	-
2	0,7	-	-	-	-	-	-	-
3	1,2	-	-	-	-	-	-	-
4	1,6	-	-	-	-	-	-	-
5	1,3	-	-	-	-	-	-	-
6	1,3	-	-	-	-	-	-	-
7	0,1	0,3	1,42	1,3	-	-	-	1,5
8	4,3	0,6	1,51	1,2	-	-	-	1,4
9	3,1	0,8	1,82	1,3	-	-	-	1,4
10	2,6	0,8	1,67	1,1	-	-	-	1,3
11	1,1	0,7	1,16	0,8	-	-	-	0,6
12	1,3	0,9	1,80	1,1	-	-	-	1,0
13	1,4	0,9	1,56	1,0	-	-	-	1,3
14	2,6	0,4	1,06	0,7	-	-	-	0,5
15	3,6	0,5	1,31	0,8	-	-	-	0,6
16	2,2	0,9	1,76	1,3	-	-	-	1,2
17	3,4	0,5	1,71	1,4	-	-	-	1,3
18	6,2	0,6	1,42	1,2	-	-	-	1,3
19	6,3	0,0	0,49	0,5	-	-	-	0,5
20	1,1	-	-	-	-	-	-	-
21	1,3	-	-	-	-	-	-	-
22	0,3	-	-	-	-	-	-	-
23	2,2	-	-	-	-	-	-	-

9 Ogólna koncepcja wdrożenia wyników

Narzędzie do krótkoterminowego planowania pracy badanej elektrociepłowni zostało opracowane w formie arkusza Microsoft Excel i składa się z następujących zintegrowanych ze sobą modułów, wraz z graficznym interfejsem użytkownika i warstwą komunikacji ze źródłem danych wejściowych i silników obliczeniowych.

- moduł prognozowania zapotrzebowania na ciepło wraz z komunikacją ze środowiskiem programistycznym R,
- moduł obliczeń termodynamicznych jednostek wytwórczych wraz z komunikacją z programem Epsilon Professional,
- moduł prognozowania współczynników poprawkowych do modelu symulacyjnego pracy turbiny gazowej z kotłem odzysknicowym wraz z interfejsem komunikacyjnym ze środowiskiem programistycznym R,
- moduł optymalizacji do doboru konfiguracji pracy jednostek wytwórczych oraz akumulatora ciepła,
- moduł generowania planów produkcyjnych i sporządzania raportów.



Rys. 9.1 Schemat ideowy narzędzia Excel do planowania produkcji

Na Rys. 9.1 przedstawiono architekturę systemową narzędzia do planowania produkcji. Narzędzie Excel posiada graficzny interfejs użytkownika i warstwę wizualizacji wyników działania poszczególnych modułów obliczeniowych. Arkusz do planowania zawiera odpowiednie makra i procedury napisane w języku VBA do:

- importu danych pogodowych (dane prognozowane i faktyczne dla miasta Toruń) z serwera FTP, na który trafiają cykliczne raporty o godz. 6:00 w postaci plików tekstowych z danymi godzinowymi *.csv od dostawcy prognozy pogody.

- importu danych procesowych z eksploatacji obiektu z systemu archiwizacji danych PGIM firmy ABB.
- komunikacji dwukierunkowej ze środowiskiem programistycznym w języku *R*, w którym zostały opracowane kody źródłowe algorytmów predykcyjnych.


Narzędzie w swojej funkcjonalności generuje wyniki w postaci raportu z planem produkcji ciepła i energii elektrycznej przez poszczególne jednostki wytwórcze w horyzoncie następnej doby. Rys. 9.2 przedstawia wizualizację wybranych zakładów Arkusza. Na podstawie wyników opracowywany jest grafik produkcji na potrzeby zgłoszenia planowanego wolumenu produkcji energii elektrycznej, w ramach rynku dnia następnego RDN. Uczestnictwo elektrociepłowni w rynku RDN wymaga, aby w dobie poprzedzającej realizację (do godz. 10:30) zgłosić ofertę sprzedaży planowanej energii elektrycznej dla każdej godziny doby.

Proces generowania planu produkcji z wykorzystaniem narzędzia opiera się kolejno na następujących działaniach, uruchamianych przez użytkownika narzędzia:

- Etap I – prognozowanie zapotrzebowanie na ciepło:
 - Z serwera FTP pobierane są faktyczne dane pogodowe z przesuwnego w czasie okna uczącego model oraz dane prognozowane obejmujące horyzont doby następnej. Następnie, pobierane są historyczne dane z systemu PGIM w zakresie mocy cieplnej oddawanej do miejskiej sieci ciepłowniczej (dla przyjętego rozmiaru okna uczącego model). Dane te są wysyłane do środowiska programistycznego *R* na potrzeby uczenia modelu. Zaimplementowano odrębne modele na okres grzewczy (Uogólniony Model Addytywny GAM – Q_{m09}) i na okres poza sezonem grzewczym (Uogólniony Model Addytywny GAM – Q_{m12}), opisane w podrozdziale 5.3. Nauczony model, generuje prognozę mocy cieplnej zapotrzebowanej przez sieć ciepłowniczą w oparciu o prognozowane dane pogodowe. Dane są zwracane do narzędzia planistycznego Excel.
- Etap II – prognozowanie możliwości wytwórczych kogeneracyjnych turbin gazowych:
 - Z bazy danych procesowych pobierane są godzinowe dane historyczne z ostatnich dni obejmujących rozmiar okna treningowego, na potrzeby uczenia modeli predykcyjnych do: współczynników poprawkowych dla mocy elektrycznej, jednostkowego zużycia energii chemicznej paliwa, masowego przepływu i temperatury spalin wylotowych z turbiny, spadku ciśnienia spalin wylotowych z turbiny, całkowitego współczynnika przenikania ciepła kotła odzysknicowego. Dane te, za pośrednictwem arkusza planistycznego Excel są wysyłane do oprogramowania Epsilon Professional, w którym dokonywane są obliczenia z modelu krzywych korekcyjnych. Jednocześnie wyznaczane są rzeczywiste wartości współczynników poprawkowych i rzeczywista wartości całkowitego współczynnika przenikania kotła (zgodnie z tokiem obliczeń opisanym w podrozdziale 6.1.1). Wyniki obliczeń wykonane w trybie kalibracji modelu termodynamicznego, są zwracane do arkusza Excel, skąd trafiają do środowiska *R*. Następnie, modele predykcyjne są uczone w oparciu o rzeczywiste dane pogodowe i procesowe.

Zaimplementowano model Uogólnionego Modelu Addytywnego GAM – Y_{m04} . Na podstawie prognozy danych pogodowych, uprzednio nauczone modele dokonują prognozy poszczególnych współczynników poprawkowych i całkowitego współczynnika przenikania kotła. Wyniki działania modeli predykcyjnych są kierowane do arkusza Excel, a następnie wraz z prognozą pogody ponownie do oprogramowania Epsilon Professional, na potrzeby obliczeń możliwości wytwórczych turbin gazowych w zakresie: prognozowanej mocy elektrycznej i cieplnej oraz zużycia paliwa gazowego. Wyniki symulacji w rozdzielczości godzinowej wysyłane są do narzędzia Excel, w celu zrealizowania kolejnego etapu w procesie planowania produkcji.

- Etap III – planowanie optymalnego profilu pracy jednostek wytwórczych
 - Na podstawie prognozy mocy cieplnej na wyprowadzeniu ciepła do sieci ciepłowniczej oraz prognozy parametrów produkcyjnych turbin gazowych obliczany jest profil pracy jednostek wytwórczych i akumulatora ciepła, dla zakładanego horyzontu czasowego planowania (maksymalizując przyjętą funkcję celu określającej umowny zysk operacyjny, zdefiniowaną w równaniu (8.1)). Obliczony plan produkcji może być ręcznie skorygowany przez użytkownika.



Rys. 9.2 Wizualizacja wybranych zakładzek Arkusza Excel do komunikacji z danymi źródłowymi, komunikacji z modelami predykcyjnymi i generowania raportu z grafikiem produkcji

10 Wnioski i uwagi końcowe

W niniejszej pracy rozważano problem krótkoterminowego planowania pracy elektrociepłowni gazowej, wyposażonej w dwie kogeneracyjne turbiny gazowe z wodnym kotłem odzysknicowym. Planowanie pracy elektrociepłowni w horyzoncie doby następnej zmierza do selekcji najbardziej korzystnego profilu pracy poszczególnych jednostek wytwórczych. Proces ten wynika z uczestnictwa elektrociepłowni w rynku dnia następnego energii elektrycznej i wymaga zgłoszenia wolumenów energii elektrycznej w dobie poprzedzającej faktyczną realizację. Na ten cel, niezbędne jest zaprognozowanie w rozdzielczości godzinowej zapotrzebowania na moc ciepłą konieczną do oddania przez elektrociepłownię do miejskiej sieci ciepłowniczej, a także zaprognozowania parametrów produkcyjnych jednostek wytwórczych w spodziewanych warunkach eksploatacyjnych, a wpływających na poziom zysku (wolumen produkowanej mocy elektrycznej, cieplnej, zużycia paliwa gazowego oraz emisji CO₂).

W ramach realizacji pracy zostały opracowane modele do prognozowania wymaganych danych do przeprowadzenia optymalizacji procesu produkcyjnego w nadchodzącej dobie. Prace naukowo-badawcze były skoncentrowane na wypracowaniu metod prognozowania, które będą wykazywały możliwie wysoką dokładność w zakładanym horyzoncie czasowym. Efektem końcowym rozprawy jest opracowane narzędzie do planowania pracy rozważanej elektrociepłowni w aktualnych warunkach rynkowych, z uwzględnieniem współpracy źródła z miejską siecią ciepłowniczą. W narzędziu zaimplementowano zintegrowane ze sobą moduły do prognozowania godzinowej mocy cieplnej na wyprowadzeniu do sieci ciepłowniczej, symulacji możliwości wytwórczych układu turbiny gazowej z wodnym kotłem odzysknicowym w warunkach eksploatacyjnych powiązanych z parametrami termofizycznymi powietrza dolotowego do turbiny. Integralną częścią narzędzia jest warstwa optymalizacji produkcji, która w oparciu o przyjętą funkcję celu określającą umowny zysk operacyjny, generuje optymalny profil pracy jednostek wytwórczych i akumulatora ciepła.

Wdrożony model zapotrzebowania na ciepło oparty jest o algorytm Uogólnionego Modelu Addytywnego GAM i został opracowany w dwóch trybach: na okres grzewczy i poza nim. W okresie grzewczym (obejmującym okres kalendarzowej zimy oraz okres przejściowy pomiędzy latem), model wykorzystuje dane pogodowe w zakresie temperatury otoczenia, prędkości wiatru i natężenia promieniowania słonecznego w skali miasta. Dodatkową zmienną wejściową jest zmienna określająca godzinę w dobie. Poza sezonem grzewczym, model zasilany jest oprócz zmienną reprezentującą godzinę w dobie, również zmiennymi określającymi dzień w roku oraz dzień tygodnia. Wnioski dotyczące modelu w świetle przedstawionych w Rozdziale 3 hipotez są następujące:

- Zastosowanie regresyjnej metody uczenia maszynowego pozwoliło na zwiększenie dokładności godzinowych prognoz zapotrzebowania na ciepło w horyzoncie doby następnej. Podczas testowania skuteczności modelu

w trakcie sezonu grzewczego, wyniki zastosowanego algorytmu GAM zostały porównane z prostymi modelami regresji liniowej i eksponentyjnej temperatury otoczenia. Model z algorytmem GAM, okazał się dokładniejszy o ponad 2,2 punkty procentowe dla błędu względnego MAPE w ujęciu całego sezonu grzewczego w 2023r. W miesiącach przejściowych pomiędzy okresem zimy, a lata, model wykorzystujący algorytm GAM wykazał mniejszy błąd względny o ok. 3,5 punktu procentowego.

- Poprawę w dokładności prognozowaniu mocy cieplnej uzyskano poprzez uwzględnienie nieliniowego wpływu dodatkowych zmiennych pogodowych objaśniających model poza temperaturą otoczenia (natężenie promieniowania słonecznego oraz prędkość wiatru). Najistotniejszą poprawę dokładności otrzymano wykorzystując godzinę doby, jako predyktor. Umożliwiło to uwzględnienie w prognozowaniu sezonowości produkcji ciepła w elektrociepłowni na przestrzeni doby, co spowodowało redukcję błędu średniokwadratowego RMSE o 22% w zestawieniu do modelu eksponentyjnego.
- W okresie poza sezonem grzewczym, opracowany model wykazał wysoką dokładność (90% godzinowych odchyleń między wartościami prognozowanymi i faktycznymi mocy cieplnej nie przekraczały 1 MW przy produkcji ciepła na poziomie od 17 do 28 MW). Było to możliwe poprzez uwzględnienie sezonowości związanej z dobowym i tygodniowym profilem poboru ciepła przez sieć na potrzeby zapotrzebowania wynikającego z potrzeb na przygotowanie ciepłej wody użytkowej.
- W rezultacie, średni błąd względny godzinowych wskazań modelu prognozowania zapotrzebowania na ciepło z algorytmem GAM, wyniósł ok. 8,5% i ok. 4% odpowiednio podczas sezonu grzewczego i poza nim.
- Opracowane modele do predykcji mocy cieplnej posiadają funkcję adaptacyjnego uczenia, którą osiągnięto poprzez zastosowanie metody przesuwnej w czasie okna z danymi uczącymi model. Wykorzystując dane treningowe z ostatnich dni poprzedzających moment wygenerowania prognozy, model jest uczony do bieżącej specyfiki poboru ciepła przez sieć ciepłowniczą w różnych okresach sezonu grzewczego i poza nim. Takie podejście umożliwia uwzględnienie aktualnej sytuacji związanej z poziomem strat ciepła, wymianą rurociągów ciepłowniczych na preizolowane, nowymi przyłączeniami odbiorców końcowych i współpracę z innymi źródłami wytwórczymi pracującymi w obrębie systemu ciepłowniczego. Przeprowadzone analizy pokazały, że dla miesięcy typowo zimowych (od grudnia do marca) rozmiar okna równy 12-15 dni pozwala na osiągnięcie najniższego błędu prognozy w dobie następnej. Podczas miesięcy przejściowych (od kwietnia do maja oraz w od października do listopada), właściwy rozmiar okna jest mniejszy i wynosi 6-8 dni.
- Model termodynamiczny do symulacji pracy układu turbiny gazowej z wodnym kotłem odzysknicowym umożliwia obliczenie niezbędnych z punktu widzenia planowania pracy elektrociepłowni parametrów, mając na względzie zmienne warunki eksploatacyjne, związane z parametrami termofizycznymi powietrza dolotowego do kompresora. Model termodynamiczny został wyposażony w warstwę kalibracji na podstawie rzeczywistych danych ruchowych,

pochodzących z przesuwanego w czasie okna z danymi historycznymi. Dzięki temu model jest adaptowany do aktualnego stanu jednostki wytwórczej i uwzględnia aspekt degradacji turbiny, stanu zanieczyszczenia kompresora i filtra powietrza. Wyniki analiz wpływu rozmiaru okna treningowego wskazują, że zastosowanie rozmiaru okna wynoszącego 14-16 dni pozwala na osiągnięcie najniższego poziomu błędu prognozowania parametrów produkcyjnych kogeneracyjnej turbiny gazowej.

- Poprzez wprowadzenie prognozy w dobie następnej współczynników poprawkowych (dla krzywych korekcyjnych od producenta) dla produkowanej mocy elektrycznej, zużycia energii chemicznej paliwa i spadku ciśnienia spalin wylotowych z turbiny, możliwe było zwiększenie dokładności godzinowej prognozy mocy elektrycznej i zużycia paliwa gazowego przez turbinę. Zaprognozowanie współczynnika poprawkowego dla temperatury i masowego przepływu spalin wylotowych z turbiny, wraz z prognozą całkowitego współczynnika przenikania ciepła kotła odzysknicowego, pozwoliło na dokładniejszą prognozę mocy cieplnej odzyskiwanej ze spalin. Średnioroczna dokładność prognozy w dobie następnej dla mocy elektrycznej, mocy cieplnej i zużycia paliwa gazowego wyniosła odpowiednio ok. 1,5%, 1,2% i 0,4%. Algorytm GAM oparty o uczenie modelu w oparciu o temperaturę powietrza dolotowego i ciśnienie atmosferyczne miał niższy błąd względny prognozowania mocy elektrycznej, w porównaniu do algorytmu regresji liniowej o ok. 17% na przestrzeni pełnego roku kalendarzowego. Dla tego samego okresu czasu, model GAM do prognozy całkowitego współczynnika przenikania ciepła, zasilany temperaturą powietrza dolotowego do turbiny, ciśnieniem atmosferycznym oraz mocą palnika dopalającego spaliny wykazał dokładność wyrażoną błędem względnym na poziomie ok. 1,2%, co przełożyło się na maksymalne odchylenia od faktycznych wartości mocy cieplnej do 0,6 MW.

Wyniki algorytmów predykcyjnych zapotrzebowania na ciepło i parametrów produkcyjnych układu turbiny gazowej z kotłem odzysknicowym, znalazły praktyczne zastosowanie w rozwiązaniu problemu planowania pracy elektrociepłowni. Poprzez uzyskiwanie dokładnych prognoz możliwe jest przeprowadzenie procesu planowania w nadchodzącej dobie, mając na względzie aspekt doboru scenariusza pracy elektrociepłowni przy optymalizacji funkcji celu maksymalizującej zysk operacyjny. Narzędzie pozwala na dokładniejsze zaprognozowanie i kontraktowanie godzinowych wolumenów produkowanej energii elektrycznej na rynku dnia następnego i minimalizację odchyłeń na rynku bilansującym. Dla zaprognozowanego profilu poboru ciepła przez sieć ciepłowniczą, możliwe jest oszacowanie mocy cieplnej produkowanej przez jednostki wytwórcze, co wpływa na dokładniejsze prognozowanie poboru gazu przez turbiny, palniki dopalające spaliny oraz kotły rezerwowo-szczytowe. Dysponując dokładniejszą prognozą zużycia paliwa gazowego, można dokonać optymalizacji procesu zakupu gazu, np. poprzez zwiększenie wolumenu gazu kupowanego w ramach giełdowych transakcji zawieranych na rynkach dnia następnego.

Narzędzie analityczne zostało zweryfikowane podczas eksploatacji badanej elektrociepłowni w różnych okresach sezonu grzewczego i poza nim. W miesiącach

zimowych, kiedy oddawana do sieci moc cieplna przewyższa możliwości wytwórcze kotłów odzysknicowych, wyniki z modułów prognostycznych pozwalają na zaplanowanie zużycia paliwa gazowego przez układ palników dopalających i kotły szczytowe. W okresie przejściowym oraz letnim, kiedy turbiny mogą współpracować z akumulatorem ciepła, narzędzie umożliwia zaplanowanie czasu pracy turbin, w celu maksymalizacji przychodów ze sprzedaży energii elektrycznej. Do głównych korzyści w aspekcie maksymalizacji zysku operacyjnego w tym okresie, należy zaliczyć dokładne prognozowanie produkowanej mocy elektrycznej turbin. Poza sezonem zimowym, układ anty-oblodzeniowy nie pracuje i temperatura powietrza dolotowego do sprężarki zmienia się na przestrzeni doby, co powoduje zróżnicowany poziom produkcji przy pełnym obciążeniu. Dzięki algorytmom predykcyjnym, możliwe jest dokładniejsze oszacowanie godzinowej produkcji energii elektrycznej na potrzeby zgłoszenia do sprzedaży na rynku dnia następnego.

Opracowane narzędzie analityczne zostało zweryfikowane dla układu źródło ciepła-sieć ciepłownicza, na przykładzie systemu ciepłowniczego miasta Toruń. Innowacyjną cechą narzędzia jest zastosowanie zaawansowanych algorytmów analizy danych w modelach predykcyjnych. Na etapie budowania narzędzia, doboru i parametryzacji algorytmów przeanalizowano dane pogodowe i procesowe z pracy kogeneracyjnych turbin gazowych z okresu trzech lat. Wyniki badań znalazły praktyczne zastosowanie w rozwiązaniu problemu optymalizacji pracy elektrociepłowni - narzędzie wraz z integralnymi modułami zostało wdrożone w przedsiębiorstwie zatrudniającym Autora i stanowi system wsparcia dla planistów produkcji elektrociepłowni PGE Toruń S.A.

Wykaz ważniejszych skrótów, oznaczeń i symboli

Wykaz ważniejszych skrótów:

ACU – akumulator ciepła
ANN – sztuczne sieci neuronowe
AR – model autoregresyjny
ARIMA - metody autoregresji szeregów czasowych
EC - elektrociepłownia
GAM – Generalized Additive Model (Uogólniony Model Addytywny)
GCV - Uogólniona Walidacja Krzyżowa
GLM – Generalized Linear Model (Uogólniony Model Liniowy)
GT – turbina gazowa
HOB – gazowy kocioł wodny
HRHWB – wodny kocioł odzysknicowy
LP – programowanie liniowe
MAPE – średni błąd względny
MILP - Programowanie liniowe całkowitoliczbowe
MSC – miejska sieć ciepłownicza
NLP - Programowanie nieliniowe
OC – odbiorca końcowy
OZE – odnawialne źródła energii
RDN – Rynek Dnia Następnego
RMSE – błąd średniokwadratowy
SF – palnik dopalający spaliny

Wykaz ważniejszych symboli:

$\dot{Q}_t$ – ciepło oddawane do miejskiej sieci ciepłowniczej (po odjęciu potrzeb własnych), MWh
 E_t^u – emisja CO₂ przez jednostkę wytwórczą u w godzinie t , MWh
 F_t^u – zużycie paliwa gazowego przez jednostkę wytwórczą u w godzinie t , MWh
 $M_{g,i}$ – masa molowa składnika i w paliwie gazowym, kg/mol
 M_g – masa molowa gazu, kg/mol
 $M_{s,i}$ – masa molowa składnika i w spalinach, kg/kmol
 N_{el} – moc elektryczna, MW
 P_t^u – produkcja energii elektrycznej przez jednostkę wytwórczą u w godzinie t , MWh
 $\dot{Q}$ – moc cieplna, MW
 T_p – temperatura powrotu MSC, K
 T_z – temperatura zasilania MSC, K
 $\hat{Y}$ – reprezentacja prognozy zmiennej Y
 b_k – funkcja bazowa
 c_h – cena ciepła, PLN/MWh
 c_e – cena emisji CO₂, PLN/t
 $c_{el,t}$ – cena energii elektrycznej w godzinie t , PLN/MWh
 c_f – cena paliwa gazowego, PLN/MWh
 c_p – średnie ciepło właściwe wody, kJ/(kg·K)
 c_s – koszt rozruchu turbiny gazowej, PLN

$g^{-1}(\boldsymbol{\eta})$ – funkcja łączenia, która łączy wartość oczekiwaną ze zmiennymi predykcyjnymi
 (kA) – całkowity współczynnik przenikania ciepła, kW/K
 $\dot{m}$ – przepływ masowy, kg/s
 n'_s – liczba moli spalin mokrych, kmol/j.p.
 p_0 – ciśnienie atmosferyczne, bar
 z_i – zawartość składnika i w paliwie gazowym,-
 $z_{s,i}$ – zawartość składnika i w spalinach, kmol/kmol
 β_k – współczynniki
 Δp_{pow} – spadek ciśnienia powietrza dolotowego, mbar
 Δp_{sp} – spadek ciśnienia spalin wylotowych, mbar
 h – entalpia właściwa, kJ/kg
 CF, CO – współczynniki poprawkowe, -
 $ED(g^{-1}(\boldsymbol{\eta}), \phi)$ – wykładniczy rozkład rodziny z parametrem skali ϕ
 HR – jednostkowe zużycie energii chemicznej paliwa, kJ/kWh
 $LMTD$ – logarytmiczna różnica temperatur, -
 NCV – wartość opałowa paliwa, kJ/kg
 Y – zmienna prognozowana
 Z – zysk operacyjny w analizowanej dobie, PLN
 f – funkcja
 p – liczba zmiennych objaśniających model
 $r, pearson$ – współczynnik korelacji Pearson'a
 $r, spearman$ – współczynnik korelacji Spearman'a
 s – funkcja wygładzająca
 $tr(F_\lambda)$ – efektywny stopień swobody
 $\mathbf{X}$ – dane objaśniające zmienną prognozowaną
 $\mathbf{Y}$ – wektor zmiennej prognozowanej z n obserwacjami
 α – współczynnik poprawkowy
 ε – błąd losowy
 λ – współczynnik kary

Bibliografia

- [1] Lichota J., Kołodziejak P., Funkcja celu elektrociepłowni i jej ograniczenia, Rynek Energii, 2018, Tom Nr 3, strony 31-25
- [2] Świerzewski M., Kalina J., Optymalizacja doboru mocy elektrociepłowni biomasowej z modułem ORC w projekcie modernizacji ciepłowni komunalnej z kotłami węglowymi typu WR, 12/2019, INSTAL, str. 14-18
- [3] Talebi B., A Review of District Heating Systems: Modeling and Optimization, 534 Frontiers in Built Environment, 2016, 2(22).
- [4] Chmielniak T., Technologie energetyczne, Wydawnictwo Naukowe PWN, 2021
- [5] Raport Urzędu Regulacji Energetyki, Energetyka ciepła w liczbach, 2022
- [6] Lygnerud K., Popovic T., Schultze S., Kortegaard H., District heating in the future - thoughts on the business model, Energy, Volume 278, 2023, 127714
- [7] Fallahnejad M., Kranzl L., Haas R., Hummel M., Müller A., García L., Persson U., District heating potential in the EU-27: Evaluating the impacts of heat demand reduction and market share growth, Applied Energy, Volume 353, Part B, 2024
- [8] Volkova A., Pakere I., Murauskaite L., Huang P., Lepiksaar K., Zhang X., 5th generation district heating and cooling (5GDHC) implementation potential in urban areas with existing district heating systems, Energy Reports, 2022, p. 10037-10047
- [9] Gürsan C., de Gooyert V., The systemic impact of a transition fuel: Does natural gas help or hinder the energy transition?, Renewable and Sustainable Energy Reviews, Volume 138, 2021
- [10] Wędzik A., Układy kombinowane produkcji energii elektrycznej, Część I, Zagadnienia ekonomiczne i rynkowe, Energetyka, Tom nr 5, 2006, str. 323-329
- [11] Fuzowski K., Strategiczne wyzwania sektora ciepłowniczego XXI wieku – cz. I, Nowa Energia, nr 1 (55)/2017
- [12] Sporleder M., Rath M., Ragwitz M., Design optimization of district heating systems: A review, Frontiers in Energy Research, Volume 10, 2022
- [13] Kazda K., Li X., A Critical Review of the Modeling and Optimization of Combined Heat and Power Dispatch, Processes, 2020, 8(4):441.
- [14] Laakkonen L., Korpela T., Kaivosoja J., Vilkkio M., Majanne Y., Nurmoranta M. Predictive Supply Temperature Optimization of District Heating Networks Using Delay Distributions. Energy Procedia 2017;116:297–309
- [15] Świątecki M., Zielasko J., (2019), Optymalizacja parametrów pracy sieci ciepłowniczej, INSTAL, 11/2019, s. 19-22
- [16] Wang C., Yuan J., Zhang J., Deng N., Zhou Z., Gao F., Multi-criteria comprehensive study on predictive algorithm of heating energy consumption of district heating station based on timeseries processing, Energy, Volume 202, 2020
- [17] Abugabbara M., Javed S., Johansson D., A simulation model for the design and analysis of district systems with simultaneous heating and cooling demands, Energy, Volume 261, Part A, 2022,
- [18] Kalina J., 2009, Optymalizacja doboru mocy bloku elektrociepłowni z kotłem na zrębki drzewne w projekcie modernizacji komunalnej ciepłowni węglowej, Energetyka nr 7 (661).
- [19] Ancona M., Bianchi M., Branchini L., Melino F., District Heating Network Design and Analysis, Energy Procedia, Volume 45, 2014, Pages 1225-1234,
- [20] Bella L., Corno A., Scaburri A., (2021), Data-driven modelling and optimal management of district heating networks, 1-6, 2021 AEIT International Annual Conference (AEIT)

- [21] Bujalski M., Madejski P., Fuzowski K., Nabagło D., Prognozowanie zapotrzebowania na ciepło w systemie ciepłowniczym z zastosowaniem zaawansowanych algorytmów analizy danych, *Energetyka Ciepła i Zawodowa*, Tom nr 1, 2021, str. 59-64
- [22] Bergsteinsson H. G., Møller J. K., Thilker C. A., Guericke D., Heller A., Nielsen T. S., Madsen H., (2022), Data-Driven Methods for Efficient Operation of District Heating Systems, In *Handbook of Low Temperature District Heating, Green Energy and Technology* (pp. 129-163), Springer.
- [23] Eguiarte O., Garrido-Marijuan A., Garay-Martinez R., Raud M., Hagu I., Data-driven assessment for the supervision of District Heating Networks, *Energy Reports*, Volume 8, Supplement 16, 2022, Pages 34-40
- [24] Touš M., Pavlas M., Putna O., Stehlík P., Crha L., Combined heat and power production planning in a waste-to-energy plant on a short-term basis, *Energy*, Volume 90, Part 1, 2015, Pages 137-147
- [25] Lichota J., Kołodziejak P., Elektrociepłownia na rynku energii, *Rynek Energii*, 2018, Tom Nr 1, strony 11-19
- [26] Wierzbński M., The economic optimisation of cogeneration power plants, *Prace Naukowe Uniwersytetu Ekonomicznego We Wrocławiu*, ISSN 1899-3192, e-ISSN 2392-0041, 2015, str. 152-162
- [27] Kowalewska E., Wilczewski G., Transformacja elektrociepłowni na tle zmian i wymogów rynku energii elektrycznej, *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej*, 2010, nr 27, s. 11-16
- [28] Kalbarczyk P., Wpływ błędów prognozy zapotrzebowania na ciepło w miejskiej sieci ciepłowniczej na koszty bilansowania elektrociepłowni uczestniczącej w hurtowym rynku energii elektrycznej w Polsce, „*Rynek Energii*”, 2004, nr 5, s. 91-96.
- [29] Łukaszewski K., Prognozowanie zapotrzebowania energii cieplnej sieci ciepłowniczej względem określonych warunków eksploatacyjnych tej sieci – model matematyczny, *Zeszyty Naukowe Akademii Morskiej w Gdyni*, 2013, nr 81, s. 63-76
- [30] Triebs M., Tsatsaronis G., From heat demand to heat supply: How to obtain more accurate feed-in time series for district heating systems, *Applied Energy*, Volume 311, 2022
- [31] Turunen J., Majanne Y., Vilkkio M., Short-term Optimization of the Operation of the CHP District Heating Plant with Heat Accumulator, *IFAC-PapersOnLine*, Volume 53, Issue 2, 2020, p. 13236-13241
- [32] Li P.F., Ge Z., Yang Z., Chen Y., Yang Y., District Heating Mode Analysis Based on Air-cooled Combined Heat and Power Station, *Entropy* 2014, 16, 1883-1901.
- [33] Wan A., Chang Q., Zhang Y., Wei C., Zhao X., Optimal Load Distribution of CHP Based on Combined Deep Learning and Genetic Algorithm, *Energies*, 2022, 15(20):7736.
- [34] Dahl M., Brun A., Kirsebom O.S., Andresen G.B., Improving short-term heat load forecasts with calendar and holiday data, *Energies* 2018, 11(7), 1-16
- [35] Dalipi F., Yayilgan Y., Gebremedhin S., Alemayehu, (2016), Data-driven Machine Learning Model in District Heating System for Heat Load Prediction, *Applied Computational Intelligence and Soft Computing*, 2016.
- [36] Dotzauer E., Simple model for prediction of loads in district-heating systems, *Applied Energy* 2002, 73, 277-284,
- [37] Baltputnis K., Petrichenko R., Sobolevsky D., Heating demand forecasting with multiple regression: Model setup and case study, *Conference: 2018 IEEE 6th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE)*
- [38] Grosswindhager S., Voigt A., Kozek M., Online short-term forecast of system heat load in district heating networks, In *Proceedings of the 31st International Symposium on Forecasting*, Prague, Czech Republic 2011

- [39] Fang T., Lahdelma R., Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system, *Applied Energy*, 2016, 179, 544–552.
- [40] Wojdyga K., Predicting heat demand for a district heating systems. *International Journal of Energy and Power Engineering* 2014, 3(5), 237–244.
- [41] Bandyopadhyay S., Hazra J., Kalyanaraman S., A machine learning based heating and cooling load forecasting approach for DHC networks. *IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT) 2018*, 1–5.
- [42] Geysen D., Aleksiejuk P., Johansson C., Thermal load forecasting in district heating networks using deep learning and advanced feature selection methods, *Energy* 2018, 157, 141–149.
- [43] Bujalski M., Madejski P., Fuzowski K., Heat demand forecasting in District Heating Network using XGBoost algorithm, *E3S Web Conf. Volume 323, 2021 V International Scientific and Technical Conference Modern Power Systems and Units (MPSU 2021)*
- [44] Le L., Nguyen H., Zhou J., Dou J., Moayed H., Estimating the heating load of buildings for smart city planning using a novel artificial intelligence technique PSO-XGBoost, *Applied Sciences* 2009, 9(13), 2714.
- [45] Saloux E., Candanedo J., Forecasting District Heating Demand using Machine Learning Algorithms, *Energy Procedia*, Volume 149, 2018, Pages 59-68,
- [46] Kurek T., Bielecki A., Świrski K., Wojdan K., Guzek M., Białek J., Brzozowski R., Serafin R., Heat demand forecasting algorithm for a Warsaw district heating network, *Energy*, Volume 217, 2021, 119347
- [47] Petrichenko R., Baltputnis K., Sobolevsky D., (2017), District heating demand short-term forecasting. 1-5. 10.1109/EEEIC.2017.7977633.
- [48] Chen Z., Xiao F., Guo F., Yan J., Interpretable machine learning for building energy management: A state-of-the-art review, *Advances in Applied Energy*, Volume 9, 2023
- [49] Khamma T., Zhang Y., Guerrier S., Boubekri M., Generalized additive models: An efficient method for short-term energy prediction in office buildings, *Energy*, Volume 213, 2020, 118834
- [50] Bianchi F., Castellini A., Tarocco P., Farinelli A., 2019, Load Forecasting in District Heating Networks: Model Comparison on a Real-World Case Study, In *Machine Learning, Optimization, and Data Science: 5th International Conference*
- [51] Bujalski M., Madejski P., Forecasting of Heat Production in Combined Heat and Power Plants Using Generalized Additive Models. *Energies*. 2021; 14(8):2331
- [52] Bujalski M., Madejski P., Fuzowski K., Day-ahead heat load forecasting during the off-season in the district heating system using Generalized Additive model, *Energy and Buildings*, Volume 278, 2023, 112630
- [53] Bujalski M., Madejski P., Fuzowski K., Zastosowanie przesuwnego okna czasowego do adaptacji modelu prognozowania zapotrzebowania na ciepło dla miejskiej sieci ciepłowniczej, *Zeszyty Energetyczne*, 2020, Tom 7, str. 267-279
- [54] Sha L., Jiang Z., Sun H., A control strategy of heating system based on adaptive model predictive control, *Energy*, Volume 273, 2023,
- [55] Stoltmann A., Jaskólski M., Bućko P., Optimization of combined heat and power (CHP) market allocation: The case of Poland, *IOP Conf. Ser.: Earth Environ. Sci.*, 214, 012036
- [56] Mallier L., Hétreux G., Hétreux R., Baudet P., A modelling framework for energy system planning: Application to CHP plants participating in the electricity market, *Energy*, Elsevier, 2021, 214, pp. 118976
- [57] Żymełka P., Szega M., Madejski P., Techno-Economic Optimization of Electricity and Heat Production in a Gas-Fired Combined Heat and Power Plant With a Heat Accumulator, *ASME. J. Energy Resour. Technol.*, 2020, 142(2): 022101

- [58] Aminov R.Z, Kozhevnikov A.I., Optimization of the operating conditions of gas-turbine power stations considering the effect of equipment deterioration, *Therm. Eng.*, 64., 715–722 (2017).
- [59] Madejski P., Żymełka P., Węzik R., Kubiczek H., Gas fired plant modeling for monitoring and optimization of electricity and heat production, 2017, 97, 455-482.
- [60] Rigo-Mariani R., Zhang C., Romagnoli A., Kraft M., A Combined Cycle Gas Turbine Model for Heat and Power Dispatch Subject to Grid Constraints, *IEEE Transactions on Sustainable Computing, IEEE*, 2019, 11 (1), pp.448-456.
- [61] Mohamed O., Khalil A., Progress in Modeling and Control of Gas Turbine Power Generation Systems: A Survey, *Energies*, 2020; 13(9):2358
- [62] Kowalczyk C. et al., Mathematical model of Combined Heat and Power Plant using GateCycle™ software. *Journal of Power Technologies*. [S.l.], v. 95, no. 3, p. 183-191. July 2015, ISSN 2083-4195.
- [63] Moon SW., Kim TS., Advanced Gas Turbine Control Logic Using Black Box Models for Enhancing Operational Flexibility and Stability, *Energies*, 2020; 13(21):5703.
- [64] Roumeliotis I., Aretakis. N., Alexiou. A., Industrial Gas Turbine Health and Performance Assessment with Field Data, *ASME J. Eng. Gas Turbines Power* 2017, 139 051202.
- [65] Tahan M., Muhammad M., Karim A., A multi-nets ANN model for real-time performance-based automatic fault diagnosis of industrial gas turbine engines, *J Braz. Soc. Mech. Sci. Eng.*, 39, 2865–2876 (2017)
- [66] de Castro-Cros. M., Velasco. M., Angulo C., Machine-Learning-Based Condition Assessment of Gas Turbines—A Review, *Energies*, 2021, 14, 8468.
- [67] Asgari H., Chen. X., Menhaj. M. B., Sainudiin R., (July 31. 2013), Artificial Neural Network-Based System Identification for a Single-Shaft Gas Turbine., *ASME. J. Eng. Gas Turbines Power*, September 2013, 135(9): 092601.
- [68] Wankhede A., Ghate V., Prediction of Power of a Combine Gas and Steam Turbine Using Artificial Neural Network, 2018, 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT), 2018, pp. 1103-1108.
- [69] Bujalski M., Madejski P., Fuzowski K., Modelowanie pracy układu turbiny gazowej z kotłem odzyskowym dla kogeneracyjnego wytwarzania energii w elektrociepłowni gazowej, *Zeszyty Energetyczne*, Tom VIII, 2021, ISBN 978-83-7493-229-5
- [70] Gülen S., Off-Design Operation In Gas Turbines for Electric Power Generation (pp. 512-548). Cambridge: Cambridge University Press. 2019
- [71] Ebigenibo S., Promise N., (2020), Off-design performance analysis of gas turbines, *Global Journal of Engineering and Technology Advances*, 4
- [72] Geete A., Thermodynamic analysis of thermal power plant with combined effect of constant inlet temperature (507.78°C) and different inlet pressures, *The IUP Journal of Mechanical Engineering*, 08, 38-49, 2015
- [73] Liu Y., Banerjee A., Kumar A., Srivastava A., Effect of Ambient Temperature on Performance of Gas Turbine Engine, *Annual Conference of the PHM Society*, 9(1), 2017
- [74] Carvahlo A., Junior E., Arrieta F., Schleiss K., Silveira N., Dias P., Prediction of gas turbine performance GE 7FA, *Proceedings of COBEM 2011, 21st Brazilian Congress of Mechanical Engineering*
- [75] Szega M., Żymełka P., Janda T., Improving the accuracy of electricity and heat production forecasting in a supervision computer system of a selected gas-fired CHP plant, *Energy*, Volume 239, Part E, 2022.
- [76] Gjoka K., Rismanchi B., Crawford R., Fifth-generation district heating and cooling systems: A review of recent advancements and implementation barriers, *Renewable and Sustainable Energy Reviews*, Volume 171, 2023, 112997
- [77] Fang T., Lahdelma R., Optimization of combined heat and power production with heat storage based on sliding time window method, *Appl. Energy* 2016, 162, 723–732.

- [78] Wang J., You S., Zong Y., Cai H., Træholt C., Dong Z.Y., Investigation of real-time flexibility of combined heat and power plants in district heating applications, *Appl. Energy*, 2019, 237, 196–209.
- [79] Mordasiewicz Ł., Bućko P., Prowadzenie ruchu małej elektrociepłowni gazowej według kryterium efektu ekonomicznego, *Rynek Energii*, Nr 4(137), 2018, str. 65-70
- [80] Sarbu I., Mirza M., Crasmareanu E., A review of modelling and optimisation techniques for district heating systems, *International Journal of Energy Research*, Volume 43, Issue 13, p. 6572-6598, 2019
- [81] Abdollahi E., Wang. H.S., Lahdelma R., Optimization of energy production of a CHP plant with heat storage., 2014, *IEEE Green Energy and Systems Conference (IGESC)*, Long Beach. CA., USA, 2014, pp. 30-34
- [82] Turunen J., Majanne. Y., Vilkkko M., Short-term Optimization of the Operation of the CHP District Heating Plant with Heat Accumulator, *IFAC-PapersOnLine*, Volume 53, Issue 2, 2020, Pages 13236-13241
- [83] Kim J., Edgar T., Optimal scheduling of combined heat and power plants using mixed-integer nonlinear programming, *Energy*, Volume 77, 2014, Pages 675-690
- [84] Wang Z., Cao L., Si H., An improved genetic algorithm for determining the optimal operation strategy of thermal energy storage tank in combined heat and power units, *Journal of Energy Storage*, Volume 43, 2021, 103313
- [85] Zidan A., Gabbar H., Eldessouky A., Optimal planning of combined heat and power systems within microgrids, *Energy*, Volume 93, Part 1, 2015, Pages 235-244
- [86] Żymelka P., Szega M., Short-term scheduling of gas-fired CHP plant with thermal storage using optimization algorithm and forecasting models, *Energy Conversion and Management*, Volume 231, 2021, 113860
- [87] Li W., Peng Y., Dai W., Applications of simulated annealing to district heating network design and extension to CMOS circuits sizing and to filter bank design, 1994, *System Modelling and Optimization, Lecture Notes in Control and Information Sciences*, vol 197, Springer
- [88] Xiong G., Shuai M., Hu X., Combined heat and power economic emission dispatch using improved bare-bone multi-objective particle swarm optimization, *Energy*, Volume 244, Part B., 2022, 123108
- [89] Kowalski R., Elektrociepłownia gazowa PGE Toruń - nowoczesność i troska o środowisko, *Nowa Energia*, 2018, Tom nr 3, str. 40-42
- [90] Szkarowski A., Łatowski L., *Ciepłownictwo*, Wydawnictwo Naukowo-Techniczne, Warszawa, 2006
- [91] Gadd H., Werner S., Heat load patterns in district heating substations, *Applied Energy*, Volume 108, 2013, Pages 176-183
- [92] Li X., Li W., Zhang R., Jiang T., Chen H., Li G., Collaborative scheduling and flexibility assessment of integrated electricity and district heating systems utilizing thermal inertia of district heating network and aggregated buildings, *Applied Energy*, Volume 258, 2020,
- [93] Merkert L., Haime AA., Hohmann S., Optimal Scheduling of Combined Heat and Power Generation Units Using the Thermal Inertia of the Connected District Heating Grid as Energy Storage, *Energies*, 2019, 12(2):266.
- [94] James G., Witten D., Hastie T., Tibshirani R., *An Introduction to Statistical Learning: with Applications in R*, New York:Springer, 2013.
- [95] Abinet E., Lehtonen M., 2020, Short-Term Forecasting of Heat Demand of Buildings for Efficient and Optimal Energy Management Based on Integrated Machine Learning Models, *IEEE Transactions on Industrial Informatics*, PP. 1-110
- [96] Sobczyk M., *Statystyka*, Wydawnictwo Naukowe PWN, 2023
- [97] Hastie T.J., (1990), *Generalized Additive Models* (1st ed.), Routledge.

- [98] Wood S.N., (2017), Generalized Additive Models: An Introduction with R. Second Edition (2nd ed.). Chapman and Hall/CRC.
- [99] Hastie T. J., (1992), Generalized additive models, Chapter 7 of Statistical Models in S eds J. M. Chambers and T. J. Hastie., Wadsworth & Brooks/Cole.
- [100] Wood S.N., (2004), Stable and efficient multiple smoothing parameter estimation for generalized additive models, J. Amer. Statist. Ass., 99:637-686
- [101] Wood S.N., (2006), Generalized Additive Models: An Introduction with R, Chapman and Hall/CRC Press.
- [102] Tiwari A., Chapter 2 - Supervised learning: From theory to applications, Editor(s): Rajiv Pandey, Sunil Kumar Khatri, Neeraj kumar Singh, Parul Verma, Artificial Intelligence and Machine Learning for EDGE Computing, Academic Press, 2022, Pages 23-32,
- [103] Perperoglou A., Sauerbrei W., Abrahamowicz M., A review of spline function procedures in R, BMC Med Res Methodol 19, 46 (2019).
- [104] Wood S. N., (2011), Fast stable restricted maximum likelihood and marginal likelihood estimation of semiparametric generalized linear models, In Journal of the Royal Statistical Society (B) (Vol. 73. Issue 1. pp. 3–36)
- [105] R Core Team, (2021), R: A language and environment for statistical computing, R Foundation for Statistical Computing, Vienna, Austria, URL <https://www.R-project.org/>.
- [106] Cristina S.S., Marina O.D., Fontina, Exergy and economic evaluation of a hybrid power plant coupling coal with solar energy, Appl. Sci., 2019, 9, 850.
- [107] Madejski P., Żymełka P., Wprowadzenie do komputerowych obliczeń symulacji pracy systemów energetycznych w programie Steag Ebsilon, Red: Wydawnictwa AGH, 2020, ISBN 978-83-66364-86-8
- [108] Brooks F.J., (2010), GE Gas Turbine Performance Characteristics, GE Power Systems, Schenectady
- [109] Swat S., (2020), Thermal cycle diagram calculation with Ebsilon Professional V14 - introduction example, 10.13140/RG.2.2.12230.29764.
- [110] Szargut J., Termodynamika, Wydawnictwo Naukowo-Techniczne PWN, wyd. 7, 2000